


TECHNICKÁ UNIVERZITA V LIBERCI
Fakulta mechatroniky, informatiky a mezioborových studií



DISERTAČNÍ PRÁCE

**Počítačová analýza
obrazu textilních struktur**

2013

Ing. Jiří Horčíčka

TECHNICKÁ UNIVERZITA V LIBERCI
Fakulta mechatroniky, informatiky a mezioborových studií

**Počítačová analýza
obrazu textilních struktur**

**Digital Image Analysis of Textile
Structure Images**

**Disertační práce
k získání akademického titulu doktor
v oboru Technická kybernetika**

Autor:	Ing. Jiří Horčíčka
Studijní program:	P 2612 Elektrotechnika a informatika
Obor:	2612V045 Technická kybernetika
Školitel:	Prof. Ing. Ivan Jaksch, CSc
Rok:	2013

Abstrakt

Disertační práce je zaměřena na automatické hodnocení textilních struktur pomocí počítačového zpracování obrazu. Hodnocení je nezbytné pro odhad vlastností textilního výrobku na základě zkoumání textilní suroviny nebo určení vlastností při zkoumání finálního produktu.

Práce řeší aplikace zkoumání vlastností příze, řezů přízí a nanovláknenných struktur. Za účelem hodnocení příze byla navržena a sestavena snímací soustava, jejíž základem je digitální řádková kamera, která doplňuje převíjecí zařízení se zásobníkem. Systém poskytuje reálné obrazy plošných struktur příze. Tyto obrazy jsou zpracovány za účelem zjištění hodnot zkoumaných vlastností.

Nanovláknenné materiály a řezy přízí jsou snímány mikroskopy. Nanovláknena jsou snímána rastrovacím elektronovým mikroskopem, řezy přízí jsou snímány optickým mikroskopem doplněným kamerou.

Řezy přízí jsou hodnoceny za účelem získání popisu jednotlivých vláken. Bylo realizováno více pokročilých algoritmů. Algoritmy řeší segmentaci obrazu, detekci vláken a rozpoznávání jejich typů. Obrazy nanovláken jsou zpracovávány za účelem změření jejich fyzikálních parametrů. Těmito parametry jsou parametr zaplnění, poloměr vláken a poloměr děr. Získané informace jsou použity pro určení vlastností nanovláknenných materiálu jako například filtrační schopnost.

Klíčová slova: textilní struktury, příze, řezy přízí, vlákno, nanovláknena, počítačové zpracování obrazu, analýza obrazu

Abstract

The Ph.D. thesis is focused on the automation in textile structures evaluation using digital image processing and analysis. The evaluation is necessary for the final textile product property estimation in a raw material examination or a property determination in the final product examination.

The thesis solves the application examining yarn, yarn slices and nanofiber materials. For the purpose of yarn examination the scanning system based on the line scan camera as a part of a winding device with a container was projected and implemented. This system provides real images of the yarn surface formations. These images are processed for the property values determination.

Nanofiber materials and yarn slices are captured with microscopes. Nanofibers are captured by the scanning electron microscope, yarn slices images are obtained by the optical microscope supplemented with a camera.

Yarn slices are evaluated in order to obtain the individual fiber description. Several advanced algorithms were realized. They solve image segmentation, fiber detection and its type recognition. Nanofiber images are processed for their physical properties measurement. These properties are a filling, a fiber radius and a hole size. Obtained information can be used to determinate the properties of nanofiber material such as the filtration ability.

Keywords: textile structures, yarn, yarn slices, fiber, nanofibers, digital image processing, image analysis

Prohlášení

Byl jsem seznámen s tím, že na mou disertační práci se plně vztahuje zákon č. 121/2000 Sb., o právu autorském, zejména §60 (školní dílo).

Beru na vědomí, že Technická univerzita v Liberci (TUL) nezasahuje do mých autorských práv užitím mé disertační práce pro vnitřní potřebu TUL.

Užiji-li disertační práci nebo poskytnu-li licenci k jejímu využití, jsem si vědom povinnosti informovat o této skutečnosti TUL; v tomto případě má TUL právo ode mne požadovat úhradu nákladů, které vynaložila na vytvoření díla, až do jejich skutečné výše.

Disertační práci jsem vypracoval samostatně s použitím uvedené literatury a na základě konzultací se školitelem.

V Liberci 22. 11. 2013

.....

Ing. Jiří Horčíčka

Poděkování

Úvodem této práce bych chtěl poděkovat v první řadě svému školiteli Prof. Ivanu Jakschovi za vedení po celou dobu studia a významnou pomoc při tvorbě této práce.

Dík patří také Výzkumnému centru TEXTIL II, díky jehož podpoře mohly vzniknout některé výsledky této práce. Poděkování také patří klastru CLUTEX, na jehož zařízení byla získána část obrazových dat použitých pro zpracování.

Za zázemí a velmi důležitou morální podporu bych rád také poděkoval celé mojí rodině.

Obsah

Seznam tabulek	15
Seznam použitých zkratk	16
Seznam použitých symbolů a operátorů.....	18
Rejstřík	20
Úvod	21
1 Současný stav.....	23
2 Cíle disertační práce.....	25
3 Textilní struktury	26
3.1 Příze	26
3.2 Řezy textiliemi.....	26
3.3 Nanovlákná	27
4 Technické a programové prostředky	29
4.1 Snímací soustava	29
4.1.1 Snímací zařízení	29
4.1.2 Optická soustava	34
4.1.3 Osvětlení.....	39
4.1.4 Parametry snímací soustavy	40
4.2 Programové prostředky	42
4.2.1 Matlab.....	42
4.2.2 Image Processing Toolbox.....	43

4.2.3	LabVIEW	43
4.2.4	LabWindows/CVI	44
4.2.5	NI Vision Development Module.....	44
4.2.6	NI Vision Acquisition Software.....	45
5	Teoretické rozborý	46
5.1	Digitalizace obrazu	46
5.1.1	Vzorkování	46
5.1.2	Kvantování	47
5.1.3	Kvalita obrazu	48
5.2	Předzpracování obrazu	48
5.2.1	Bodové jasové transformace	48
5.2.1.1	Jasové korekce	49
5.2.1.2	Modifikace jasové stupnice.....	49
5.2.2	Lokální předzpracování.....	50
5.2.2.1	Filtrace	50
5.2.2.2	Detektory hran	50
5.3	Integrální transformace.....	54
5.4	Segmentace	57
5.4.1	Segmentace prahováním	57
5.4.1.1	Metody určování prahu	57
5.4.2	Segmentace na základě detekce hran	58
5.4.3	Segmentace narůstáním oblastí	58
5.4.4	Segmentace srovnáváním se vzorem	59
5.5	Matematická morfologie	59
5.5.1	Základní morfologické pojmy.....	59
5.5.2	Binární matematická morfologie.....	60
5.5.2.1	Dilatace	60
5.5.2.2	Eroze	60
5.5.2.3	Otevření a uzavření	61

5.5.3	Skelet	62
5.6	Popis nalezených objektů	63
5.7	Porozumění obsahu obrazu	63
5.7.1	Sémantické metody segmentace a interpretace obrazu.....	63
5.8	Přístup k vyhodnocení	64
5.9	Houghova transformace.....	65
5.10	Řetězový kód	68
5.10.1	Úprava hraničních objektů	70
5.10.2	Použití.....	73
5.10.3	Spektrální příznaky	73
5.10.3.1	Další příznaky.....	77
5.11	Doplňování neuzavřených hranic vláken	77
5.12	Separace segmentů a vláken.....	78
5.12.1	Separace pomocí rozvodů	79
5.12.2	Separace založená na použití váženého skeletu.....	83
5.13	Metody rozpoznávání	85
5.13.1	Principy rozpoznávání a základní pojmy	85
5.13.2	Rozpoznávací systém založený na příznakovém popisu	86
5.13.3	Metoda diskriminačních funkcí.....	87
5.13.4	Metoda minimální vzdálenosti.....	88
5.13.5	Metoda minimální vzdálenosti s reprezentací etalonem.....	88
5.13.6	Metoda maximální pravděpodobnosti.....	89
5.13.7	Výběr a volba příznaků	91
5.13.8	Učení a klasifikace bez učitele.....	92
6	Detekce vláken pomocí Houghovy transformace.....	93
7	Separace vláken pomocí váženého skeletu.....	96

8 Rozpoznávání vláken směsné příze.....	100
9 Měření fyzikálních vlastností nanovláken.....	103
9.1 Postup zpracování.....	103
9.1.1 Segmentace.....	103
9.1.2 Poloměr vláken.....	106
9.1.3 Velikost děr	110
9.2 Výsledky	111
10 Dynamické měření parametrů příze	114
10.1 Snímací soustava	114
10.2 Postup vyhodnocení.....	116
Závěr.....	121
Reference	123
Seznam publikací a dalších výsledků.....	128
Přílohy	130
A Detekce vláken pomocí Houghovy transformace.....	130
B Řetězový kód a spektrální příznaky	133
C Rozpoznávání vláken směsné příze.....	136
D Měření fyzikálních vlastností nanovláken.....	138
E Chlupatost příze	150

Seznam obrázků

Obrázek 1: Perspektivní projekce do roviny.	34
Obrázek 2: Zobrazení tenkou spojnou čočkou.	35
Obrázek 3: Hrana v obraze.	51
Obrázek 4: Filtrace obrazu v prostorové nebo frekvenční oblasti.	55
Obrázek 5: (a) Čtverec. (b) Skelet čtverce. (c) Obdélník. (d) Skelet obdélníku.	62
Obrázek 6: (a) Kruh. (b) Skelet získaný programem (neodpovídá teorii). (c) Skelet kruhu (jediný bod - střed) odpovídající teorii.	62
Obrázek 7: Parametricky popsaná úsečka.	66
Obrázek 8: Binární obrázek vstupující do Houghovy transformace. Obraz je invertován.	67
Obrázek 9: Akumulátor odpovídající obrázku 8 jako vstupu Houghovy transformace.	67
Obrázek 10: Absolutní řetězový kód pro osmiokolí.	69
Obrázek 11: Relativní řetězový kód pro osmiokolí.	69
Obrázek 12: Způsob tvorby řetězového kódu. (a) Absolutní řetězový kód. (b) Relativní řetězový kód.	70
Obrázek 13: Nejednoznačnost při aplikaci řetězového kódu.	71
Obrázek 14: Možnosti realizace řetězového kódu.	71
Obrázek 15: Strukturní elementy L Golayovy abecedy.	72
Obrázek 16: Problém nejednoznačnosti při tvorbě řetězového kódu. (a) Detail segmentu, na něž nelze aplikovat zvolenou realizaci. (b) Upravený segment pro aplikaci řetězového kódu.	72
Obrázek 17: Uzavřená hranice použitá pro výpočet spektrálních příznaků. Obrázek je invertován kvůli tisku.	75
Obrázek 18: Kumulovaný řetězový kód získaný z uzavřené hranice na obrázku 17.	75
Obrázek 19: Upravený kumulovaný kód vypočítaný z kumulovaného kódu na obrázku 18. .	76
Obrázek 20: Spektrum vytvořené z upraveného kumulovaného kódu na obrázku 19.	76
Obrázek 23: (a) Přerušená hranice vlákna se zvýrazněním místa přerušení. (b) Uzavření segmentů úsečkami.	78
Obrázek 24: Dotýkající se vlákna se zvýrazněním míst dotyku.	79
Obrázek 25: (a) Vstupní obrázek získaný předzpracováním. (b) Vzdálenostní funkce.	80
Obrázek 26: Ilustrační obrázek opačné vzdálenostní funkce pro tři vlákna.	80
Obrázek 27: Znázornění úmoří a rozvodí.	81

Obrázek 28: (a) Linie rozvodí oddělující jednotlivá úmoří. (b) Zobrazení linií rozvodí do vstupního obrázku.....	81
Obrázek 29: Označovaná oddělená vlákna.	82
Obrázek 30: Problém segmentace rozvodí.....	82
Obrázek 31: (a) a (b) Spojené oblasti. (c) a (d) Nespojené oblasti.	83
Obrázek 32: Skeletonizace: (a) Vstupní objekt. (b) Po provedení jedné eroze. (c) Po provedení druhé eroze. (c) Po provedení třetí eroze. (e) Vážený skelet.	84
Obrázek 33: Vzdálenostní profil skeletu.	84
Obrázek 34: Obecné schéma rozpoznávače	85
Obrázek 35: Systém s N vstupy a jedním výstupem.	87
Obrázek 36: Schéma klasifikátoru s diskriminačními funkcemi.....	87
Obrázek 37: Schéma klasifikátoru s reprezentací pomocí etalonem.....	89
Obrázek 38: Schéma klasifikátoru s výpočtem maximální pravděpodobnosti.	90
Obrázek 39: Podmíněná hustota pravděpodobnosti pro vektory příznaků se dvěma složkami.	91
Obrázek 40: Obrázek zobrazující vstupní a výstupní objekty umožňující vizuální kontrolu úspěšnosti detekce.....	94
Obrázek 41: Binární obrázek vstupující do Houghovy transformace.	95
Obrázek 42: Grafické znázornění akumulátoru náležícího k obrázku 41. K zobrazení je použito teplotní stupnice.	95
Obrázek 43: Příčný řez: (a) Vstupní obrázek. (b) Naprahovaný obrázek. (c) Předzpracovaný obrázek určený ke zpracování.....	96
Obrázek 44: Průběh profilu váženého skeletu odpovídajícího skeletu z obrázku 45(b) s vyznačenými body spojů.	97
Obrázek 45: (a) Získaný vážený skelet zobrazený v teplotní stupnici. (b) Vzdálenostní funkce se zobrazením upraveného skeletu. (c) Označovaný obrázek oddělených vláken.	97
Obrázek 46: Síť skeletu: (a) Vstupní obrázek. (b) Skelet obrázku.	99
Obrázek 47: Řez přízí s více typy vláken.....	101
Obrázek 48: Vizualizace výsledků rozpoznávání.	102
Obrázek 49: Výřez snímku nanovláknenné struktury.	104
Obrázek 50: Vizualizace hran ve vstupním obraze. Zelené hrany jsou získány pomocí hranového detektoru, modře jsou znázorněny prodlužující hranové segmenty a červené jsou spojnice dvou hran.	105
Obrázek 51: Skelet vláken a hranice vláken. Skelet je červený, hranice modré.....	106

Obrázek 52: Detail skeletu s roztřepením a vypsáním relativním řetězovým kódem.	107
Obrázek 53: Vzdálenostní funkce zobrazená v teplotní stupnici.	108
Obrázek 54: Segmentovaný obrázek. Binární obrázek je označovaný.	109
Obrázek 55: Skelet děr a hranice děr. Skelet je červený, hranice jsou modré.	110
Obrázek 56: Segmentovaný obrázek děr po aplikaci transformace rozvodí. Obrázek je označován.	111
Obrázek 57: Histogram poloměrů vláken.	112
Obrázek 58: Histogram velikostí děr (poloměr vepsaných kružnic).	113
Obrázek 59: Snímek zařízení.	115
Obrázek 60: Bližší pohled na snímací soustavu.	116
Obrázek 61: Bubnový zásobník příze.	117
Obrázek 62: Snímek příze na zásobníku.	117
Obrázek 63: Jasový profil.	117
Obrázek 64: Měření průměru příze.	117
Obrázek 65: Snímek příze na zásobníku.	117
Obrázek 66: Binární obrázek příze bez chlupů.	117
Obrázek 67: Binární obrázek chlupů příze s konturami jednotlivých přízí.	118
Obrázek 68: Vykreslení nalezených obrysů příze a vláken do vstupního obrázku.	118
Obrázek 69: Příze na zásobníku.	120
Obrázek 70: Semivariogramy.	120
Obrázek 71: Příčný řez hedvábím.	130
Obrázek 72: Binární obrázek získaný předzpracováním z obrázku 71. Obrázek je invertován.	131
Obrázek 73: Akumulátor Houghovy transformace odpovídající vstupnímu obrázku 71.	131
Obrázek 74: Kumulovaný řetězový kód čtverce.	133
Obrázek 75: Upravený kumulovaný řetězový kód čtverce.	133
Obrázek 76: Spektrum získané z upraveného kumulovaného kódu na obrázku 75. Je naznačeno logaritmické dělení pro tvorbu pásem, ve kterých jsou hodnoty sčítané do spektrálních příznaků.	134
Obrázek 77: Kumulovaný řetězový kód kružnice.	134
Obrázek 78: Upravený kumulovaný řetězový kód kružnice.	135
Obrázek 79: Spektrum získané z upraveného kumulovaného kódu na obrázku 78. Je naznačeno logaritmické dělení pro tvorbu pásem, ve kterých jsou hodnoty sčítané do spektrálních příznaků.	135

Obrázek 80: Příčný řez s více typy vláken.	136
Obrázek 81: Vlákná prvního typu (třídy) z řezu na obrázku 80. Obrázek je invertován.	136
Obrázek 82: Vlákná druhého typu (třídy) z řezu na obrázku 80. Obrázek je invertován.	137
Obrázek 83: Grafické znázornění typů vláken do vstupního obrázku 80. Zeleně jsou označena vlákna první třídy, červeně vlákna třídy druhé.	137
Obrázek 84: Snímek nanovláknenné struktury nasnímaný elektronovým mikroskopem.	138
Obrázek 85: Snímek nanovláknenné struktury s vizualizací oblastí výřezů.	139
Obrázek 86: Snímek nanovláknenné struktury s vizualizací oblastí výřezů.	140
Obrázek 87: Obrázek vstupující do zpracování.	142
Obrázek 88: Hranový obrázek. Hrany představují hranice vláken.	142
Obrázek 89: Binární obrázek získaný prahováním vstupního obrázku.	143
Obrázek 90: Grafické znázornění zakřivení hranic vláken v barevné teplotní stupnici. Hodnoty jsou pro vizuální názornost vyváženy vhodným koeficientem.	143
Obrázek 91: Vizualizace hran ve vstupním obraze. Zelené hrany jsou získány pomocí hranového detektoru, modře jsou znázorněny prodlužující hranové segmenty a červené jsou spojnice dvou hran.	144
Obrázek 92: Součet obrázku úplných hran a naprahovaného obrázku.	144
Obrázek 93: Upravený skelet naprahovaného obrázku.	145
Obrázek 94: Aplikace podmíněné dilatace k získání objektů odpovídající vláknům.	145
Obrázek 95: Označkový obrázek vláken.	146
Obrázek 96: Upravený skelet podmíněné dilatace.	146
Obrázek 97: Vizualizace konečných hran na vstupním obrázku.	147
Obrázek 98: Vizualizace vzdálenostní funkce vláken.	147
Obrázek 99: Označkový obrázek děr.	148
Obrázek 100: Vizualizace vzdálenostní funkce děr.	148
Obrázek 101: Vizualizace výstupu transformace rozvodí.	149
Obrázek 102: Upravený skelet děr.	149
Obrázek 103: Výřez snímku ze zásobníku použitý k hodnocení chlupatosti.	150
Obrázek 104: Binární obrázek obsahující pouze těla paralelně uložených přízí.	151
Obrázek 105: Binární obrázek obsahující odstávající vlákna (chlupy).	151
Obrázek 106: Průběh chlupatosti příze na snímku 103 pro výřez se 400 řádky.	152
Obrázek 107: Průběh chlupatosti příze na snímku 103. Data obsahují 4000 obrazových řádků.	152

Seznam tabulek

Tabulka 1: Určení expoziční hodnoty na základě expozičních parametrů.....	37
Tabulka 2: Řetězové kódy odpovídající obrázku 12.	70
Tabulka 3: Relativní řetězové kódy a jejich postupné sumace.	108
Tabulka 4: Výsledky měření vláken.....	113
Tabulka 5: Výsledky měření velikosti děr.	113
Tabulka 6: Datový výstup z algoritmu využívající Houghovu transformaci.	132
Tabulka 7: Hodnoty měření v závislosti na velikosti obrazových dat.	139
Tabulka 8: Hodnoty měření oblastí 1 – 4.	140
Tabulka 9: Hodnoty měření oblastí 5 – 8.	141
Tabulka 10: Hodnoty měření oblastí 9 – 12.	141
Tabulka 11: Hodnoty měření oblastí 13 – 16.	141

Seznam použitých zkratk

<i>A/D</i>	Analog to Digital
<i>ANSI</i>	American National Standards Institute
<i>BSI</i>	Back-side Illumination
<i>CCD</i>	Charge Coupled Device
<i>CMOS</i>	Complementary Metal Oxid Semiconductor
<i>CVI</i>	C For Virtual Instrumentation (Labwindows/CVI)
<i>DFT</i>	diskrétní Fourierova transformace (anglicky <i>Discrete Fourier transform</i>)
<i>DOS</i>	Disc Operation System
<i>edgel</i>	hranový obrazový bod (anglicky <i>edge element</i>)
<i>EV</i>	expoziční hodnota (anglicky <i>exposure value</i>)
<i>FF</i>	Full Frame
<i>FIT</i>	Frame Interlane Transfer
<i>fps</i>	snímková frekvence (anglicky <i>frames per second</i>)
<i>FSI</i>	Front-side Illumination
<i>FT</i>	Fourierova transformace (anglicky <i>Fourier transform</i>)
<i>FTD</i>	Fourierova transformace diskretních signálů (anglicky <i>Fourier transform of discrete signals</i>)
<i>GigE</i>	Gigabite Ethernet
<i>HCCD</i>	Horizontal Charge Coupled Device
<i>IDFT</i>	inverzní diskretní Fourierova transformace (anglicky <i>Inverse Discrete Fourier transform</i>)
<i>IEEE-1394</i>	sériové rozhraní PC pro multimediální periferie (také označováno jako FireWire nebo i.Link)
<i>IFT</i>	inverzní Fourierova transformace (anglicky <i>Inverse Fourier transform</i>)
<i>IL</i>	Interlane Transfer
<i>IR</i>	Infrared
<i>ISO</i>	International Organization for Standardization
<i>LabVIEW</i>	Laboratory Virtual Instruments Engineering Workbench
<i>LED</i>	Light Emitted Diod
<i>LoG</i>	Laplacian of Gaussian
<i>lps</i>	řádková frekvence (anglicky <i>lines per second</i>)

<i>LV</i>	LabVIEW
<i>Matlab</i>	Matrix Laboratory
<i>MOS</i>	Metal Oxide Semiconductor
<i>MPx</i>	Megapixel
<i>NI</i>	National Instruments
<i>pixel</i>	základní jednotka digitalizovaného obrázku (anglicky <i>picture element</i>)
<i>TDI</i>	Time Delay Integration
<i>USB</i>	Universal Serial Bus
<i>VA</i>	Vision Assistant
<i>VAS</i>	Vision Acquisition Software
<i>VCCD</i>	Vertical Charge Coupled Device
<i>VDM</i>	Vision Development Module

Seznam použitých symbolů a operátorů

$*$	konvoluce
\oplus	dilatace
\otimes	operátor transformace tref či miň
∇	gradient
∇^2	operátor Laplacián
\circ	otevření
\bullet	uzavření
a	předmětová vzdálenost
a'	obrazová vzdálenost
d	Euklidovská vzdálenost
D	hloubka poklesu váženého skeletu
d_M	Mahalanobisova vzdálenost
d'_M	tloušťka mezikroužku
d_{max}	maximální vzdálenost váženého skeletu
d_{min}	minimální vzdálenost váženého skeletu
e	Eulerovo číslo
e	náboj elektronu
$f(t)$	spojitý signál
$f(x,y)$	obrazová funkce
$F[k]$	diskrétní signál
$F\{f(t)\}$	Fourierova transformace funkce $f(t)$
$F^{-1}\{F(\omega)\}$	inverzní Fourierova transformace funkce $F(\omega)$
f_s	vzorkovací frekvence
h	Plancova konstanta
L	celková délka váženého skeletu
p	hybnost
Σ	kovarianční matice
T	třída
\mathbf{T}	transformační matice
U	urychlovací napětí
v_0	výtah objektivu

x	vektor příznaků
y	velikost předmětu
y'	velikost obrazu
λ	vlnová délka
π	Ludolfovo číslo
σ	rozptyl
Ψ	směr gradientu
Θ	eroze
\oslash	operátor ztenčování

Rejstřík

- absolutní řetězový kód, 69
- Bayerova maska, 32, 40
- Camera Link, 31, 41, 45
- CCD, 29, 41
- CMOS, 29, 41
- compact vision systém, 21
- detektor hran, 50
- elektronový mikroskop, 33
- elektrostatické zvlákňování, 27
- Euklidovská vzdálenost, 89
- Femlab, 24
- formát snímáče, 40, 41
- Fourierova transformace, 52, 54, 73
- Gaussian, 53
- GigE Vision, 41, 45
- Houghova transformace, 65, 93
- IEEE 1394, 45
- Image Processing Toolbox, 43
- kamera
 - řádková. viz řádková kamera
- klasifikace, 85
- konvoluce, 53
- kovariance, 90
- kovarianční matice, 90
- kumulovaný řetězový kód, 69
- kvantování, 46
- LabVIEW, 43
- LabWindows/CVI, 44
- Lucia G, 24
- Mahalanobisova vzdálenost, 89
- Matlab, 24, 42
- měkký řez, 27
- mikrotom, 27
- množina
 - testovací. viz testovací množina
 - trénovací. viz trénovací množina
- nanovlákna, 27
- NI Vision Acquisition Software, 45
- NI Vision Development Module, 44
- nit, 23
- ohnisková vzdálenost, 41
- optické záření, 29
- optoelektronický snímáč, 29
- osvětlovač, 39, 42
- pletenina, 23
- počítačové vidění, 21
- pramen, 23
- přást, 23
- příze, 23, 26, 114
- relativní řetězový kód, 69
- řádková frekvence, 41
- řádková kamera, 41, 114
- řetězový kód, 68
 - absolutní. viz absolutní řetězový kód
 - kumulovaný. viz kumulovaný řetězový kód
 - relativní. viz relativní řetězový kód
- řez
 - měkký. viz měkký řez
 - tvrdý. viz tvrdý řez
- řez přízí, 23
- řez textilií, 26
- snímková frekvence, 41
- strojové vidění, 21
- testovací množina, 86
- testování, 86
- tkanina, 23
- transformace
 - Fourierova. viz Fourierova transformace
 - Houghova. viz Houghova transformace
 - rozvodí. viz transformace rozvodí
- transformace rozvodí, 79
- trénovací množina, 86
- trénování, 86
- třída, 85
- tvrdý řez, 27
- učení, 85
- USB, 41, 45
- videometrie, 21, 34
- výtah objektivu, 41
- vzorkování, 46
- základní clonové číslo, 41

Úvod

Počítačové zpracování obrazu představuje v současné době významnou oblast průmyslové techniky, vědy a mnoha dalších oborů. V současnosti se výrazně zvyšuje průmyslová automatizace, ve které se strojové vidění a průmyslové zpracování obrazu úspěšně uplatňuje. Systémy počítačového vidění mají často za úkol nahradit člověka především ve vizuální kontrole z důvodu zvýšení spolehlivosti, výkonnosti nebo snížení výrobních nákladů. Výstupem takových systémů počítačového vidění je zpravidla binární informace o správnosti průběhu výrobních procesů nebo bezvadnosti výrobků. Ve složitějších případech je kromě kontroly potřeba provádět měření. Takové vyhodnocení obrazu se nazývá videometrie.

Počítačové vidění skýtá mnoho výhod, na druhé straně i nevýhody. Vstupem do jakéhokoli systému, ať už vyhodnocovacího softwaru v osobním počítači nebo do průmyslového systému v podobě například „compact vision“ systému, jsou data v podobě digitálního obrazu. K tomu se ve standardních případech používají snímací zařízení doplněná optikou a osvětlovačem snímání scény. A právě tato první fáze sejmутí obrazu představuje často problém, kdy se nepodaří získat obrazová data obsahující námi požadovanou vizuální informaci. V takovém případě je sebelepší vyhodnocovací algoritmus bezmocný. Příčinami těchto problémů mohou být například rušivé okolního osvětlení, použití nevhodného osvětlovače, nedodržení konstantních podmínek z důvodů opakovatelnosti, špatné zaostření, nevhodné parametry snímání a mnohé další. Zjednodušeně se dá tvrdit, že pokud je v digitálním obrázku zobrazeném například na monitoru vidět okem to, co chceme kontrolovat, měřit nebo jinak vyhodnocovat, lze navrhnout a realizovat algoritmus, který tuto činnost bude provádět automaticky.

Naproti tomu výhodami jsou bezkontaktnost přístupu nebo možnost vizualizace vyplývající z metody, kdy lze ukládat vybrané nebo všechny snímky nebo do obrazu doplňovat grafiku odpovídající výstupu. To je velmi užitečné například pro kontrolu spolehlivosti systému nebo získání statistiky výroby. Další možností je poloautomatické vyhodnocování s uživatelským vstupem využitelné v některých náročnějších neprůmyslových aplikacích.

I přes svoje široké uplatnění je řada průmyslových odvětví, ve kterých se systémy počítačového vidění ještě nepoužívají. Jedná se o některá odvětví textilní výroby.

Výzkum v oblasti textilního průmyslu má na Technické univerzitě v Liberci dlouhou tradici. Na tu navázaly některé projekty Výzkumného centra TEXTIL (VCT) a Výzkumného centra TEXTIL II (VCT II). To sdružovalo pracoviště několika fakult univerzity a Výzkumný ústav textilních strojů. V rámci VCT II byla řešena řada úloh automatizace zpracování

obrazových dat textilních struktur, případně i návrh a realizace snímací soustavy pro jejich získání a následné zpracování.

Tato práce ukazuje konkrétní realizované aplikace. Ty prezentují možné přístupy zpracování obrazových dat, která byla již dříve k dispozici a jenom nebyla zpracována tak pokročilými automatickými postupy. Je ukázána ale i aplikace, jejíž součástí je vedle části zpracování obrazových dat i snímací soustava.

1 Současný stav

Využití nástrojů počítačového zpracování obrazu v textilním průmyslu je motivováno především snahou výrobců o dosažení co nejlepší kvality výrobků. Vedle toho se tyto přístupy uplatňují také na vědeckých pracovištích univerzit, kde se testují nové textilní materiály nebo vyvíjejí nové hodnotící metody. Kromě optických metod, ve kterých se uplatňují různé typy snímačů optického záření, se využívají i jiné fyzikální principy jako například kapacitní.

Oba tyto přístupy využívá například komerční zařízení *Uster Tester* od firmy Uster Technologies, které je v současné době jedno z nejrozšířenějších. Toto měřicí zařízení je schopno vyhodnocovat *přízi*¹, *přást*² nebo *pramen*³. Z měřených parametrů můžeme uvést *hmotovou nestejnoměrnost*⁴ nebo *chlupatost*⁵. Měření jsou prováděna na jednotlivých útvarech délkových textilií z důvodu jejich použití pro výrobu plošných textilií, kterými jsou *tkaniny*⁶ nebo *pleteniny*⁷. Je tedy potřeba předpovědět vzhled plošné textilie ještě před její výrobou. Obraz takové textilie může být do jisté míry ovlivněn odlišnostmi jednotlivých *nití*⁸. Pro hodnocení parametrů plošných textilií se simuluje vzhled plošné textilie. Nevýhodou tohoto přístupu je jeho závislost na způsobu provedení simulace.

Možným přístupem pro hodnocení vzhledu příze v ploše je její navinutí na desku paralelně vedle sebe v mnoha ovinech se zadanou roztečí. Na základě existujících etalonů se poté provádí subjektivní hodnocení, kdy se testovaný vzorek přiřadí k jednomu z etalonů. Tento přístup je, z důvodu nutné přípravy hodnoceného vzorku, zdlouhavý a je samozřejmě zatížen individuálním přístupem každého hodnotitele.

Hodnocení dalších textilních struktur pomocí obrazové analýzy se na vědeckých pracovištích realizuje pomocí standardních technických a programových prostředků. Při hodnocení *řezů přízí*⁹ se ke snímání používá optický mikroskop, který se pomocí speciálního

¹ anglicky *yarn*; délková textilie ze spřadatelných vláken zpevněná zákrutem při předení; podrobněji v kapitole 3.1

² anglicky *roving*; délková textilie ze spřadatelných vláken, která jsou zpevněna buď zaoblováním nebo mírným zákrutem; jedná se o poslední meziprodukt před výrobou

³ anglicky *sliver*; délková textilie ze spřadatelných vláken, ve které jsou jednotlivá vlákna spojena vzájemnou soudržností; podle výrobního stroje se označuje jako mykanec, česanec nebo posukovaný pramen; prameny jsou většinou velmi silné

⁴ anglicky *mass variation*

⁵ anglicky *hairiness*

⁶ anglicky *woven fabric*; plošný textilní útvar vzniklý provázáním minimálně dvou soustav nití označovaných jako osnova a útek

⁷ anglicky *knitted fabric*; plošný textilní útvar vzniklý provázáním jedné nebo více nití formou oček

⁸ nadřazený pojem pro délkové útvary

⁹ anglicky *yarn slices*; podrobněji v kapitole 3.2

adaptéru doplní kamerou. Získané mikroskopické snímky často procházejí manuálním zpracováním, kdy se informace o jednotlivých vláknenných a nevláknenných útvarech získávají ručně. Další vyhodnocení již může probíhat automaticky pomocí existujících norem.

Mezi programové prostředky, které se používají za tímto účelem, patří například *Lucia G*, *Matlab*¹⁰ nebo *Femlab*¹¹. Program *Lucia* slouží k analýze obrazu a umožňuje komunikaci se snímacím zařízením. Obsahuje ale pouze základní funkce počítačového zpracování obrazu bez možnosti realizace sofistikovanějších postupů zpracování a je využíván prakticky pouze odborníky zabývajícími se textiliemi. *Matlab* je velmi silný nástroj využívaný především ve vědecké sféře. V současnosti neexistují pro analýzu obrazu jakýchkoliv textilních struktur v *Matlabu* navržené a odbornými pracovišti běžně používané pokročilejší postupy zpracování. Jako nadstavbu *Matlabu* lze použít *Femlab*, který je určen pro modelování a analýzu fyzikálních jevů jako přenosy tepla, proudění, akustiky a mnoho dalších jevů.

Další skupinou textilních struktur, které je potřeba hodnotit, jsou nanovláknenné materiály¹². K jejich nasnímání je použito elektronového mikroskopu. Měření poloměru nanovláken na obrazových datech je ukázáno v práci [1]. Uvedené řešení umožňuje určení hodnot poloměrů mimo místa křížení v nanovláknenných vrstvách.

¹⁰ podrobněji v kapitole 4.2.1

¹¹ produkt švédské společnosti *COMSOL*

¹² podrobněji v kapitole 3.3

2 Cíle disertační práce

Práce si klade za cíl navrhnout a realizovat přístupy hodnocení vybraných textilních struktur pomocí počítačového zpracování obrazu na jejich snímcích. Výsledné postupy budou automatizovat hodnocení vlastností daných textilií.

Jednou ze zkoumaných textilií je příze. K jejímu nasnímání je potřeba navrhnout a postavit snímací soustavu, která bude součástí převíjecího zařízení. Na něm bude realizováno dynamické snímání a hodnocení vlastností převíjené příze.

Další textilní struktury jsou příčné řezy přízí. Budou řešeny postupy, které realizují požadované funkce na dodaných mikroskopických snímcích a použijí se pokročilé metody segmentace a rozpoznávání typů vláken.

Posledním typem zkoumaných textilií jsou nanovláknenné materiály. Obrazová data jsou nasnímána pomocí elektronového mikroskopu a úkolem je vytvořit algoritmy, které budou měřit jejich fyzikální parametry.

Výsledky hodnocení textilních struktur se používají pro určování vlastností vyráběných textilií a stanovení vhodnosti použitelnosti pro různé aplikace v praxi.

3 Textilní struktury

V této kapitole jsou popsány textilní struktury, jejichž digitální obraz je zpracováván pomocí počítačového zpracování obrazu. Konkrétně se jedná o příčné řezy, jejichž mikroskopický obraz je získán pomocí optického mikroskopu doplněného o kameru (kapitola 6, 7 a 8). Dále to jsou obrazy příze, která je snímána snímací soustavou s řádkovou kamerou a řádkovým osvětlovačem na zásobníku (kapitola 10). Poslední skupinou jsou nanovláknenné struktury, jejichž obrazová data jsou získána pomocí rastrovacího elektronového mikroskopu (kapitola 9).

3.1 Příze

Příze představuje délkovou textilií vytvořenou spřádatelnými vlákny, která jsou zpevněná zákrutem při předení. Přízí se rozumí jednoduchá nit získaná z dopřádacího stroje. Její strukturu lze rozdělit na oblast jádra, které představuje nosný celek, a obal tvořený odstávajícími konci vláken [2]. Blízko osy příze jsou vlákna stlačena díky působení mechanických sil v procesu kroucení. Průměr příze určuje oblast chlupatosti a tělo příze. Tělo příze se nachází kolem osy, vlákna jsou v něm těsně uspořádána a díky mechanicko-fyzikálním zákonitostem se zde moc neuplatňuje individuální charakter vláken. Vnější oblast chlupatosti obsahuje volně uspořádaná vlákna. Hodnota průměru jako hraniční hodnotu pro určování chlupatosti se stanovuje pomocí teoretických modelů a experimentálních metodik [3]. Nejčastěji se ke stanovení využijí krycí schopnosti příze nebo hodnoty zaplnění příze.

3.2 Řezy textiliemi

Jednou skupinou jsou řezy textiliemi. Řezem textilie se označuje protnutí textilie rovinou svírající příslušný úhel s danými osami [4]. Jedna osa textilie je většinou totožná se směrem průchodu strojem. Rozlišují se dva základní typy řezů, a to řez příčný a řez podélný. Příčný řez neboli průřez je vedený kolmo ke směru průchodu textilie strojem a řez podélný je k tomuto směru rovnoběžný. Pro vlákna, hedvábí a příze se nejčastěji používají řezy příčné. Před vlastní tvorbou řezu je textilie zalita v příslušném médiu, které má za úkol její fixaci. Podle druhu média se řezy dělí na řezy měkké a tvrdé.

U řezů tvrdých se jako médium volí materiál na bázi epoxidové pryskyřice. Provedením metalografického výbrusu lze u tvrdých řezů ještě zvýšit kvalitu obrazu. Včelího vosku nebo parafínu je jako média užito u řezů měkkých. Při tvorbě těchto řezů se navíc médium s textilií před řezáním mrazí. K vlastnímu řezání se používá zařízení mikrotom. Jako materiál pro nože je použita ocel u řezů měkkých, respektive skla nebo diamantu pro řezy tvrdé. Minimální tloušťka řezů se pohybuje cca $3 - 5\mu\text{m}$ u tvrdých řezů, respektive cca $10\mu\text{m}$ u řezů měkkých, které jsou obvykle méně pracné než řezy tvrdé.

3.3 Nanovlákná

Nanovlákná jsou textilní útvary o definovaných rozměrech a vlastnostech. Průměr vláken je menší než $1\mu\text{m}$, jedná se tedy o submikronová vlákna, a délka ho významně přesahuje [5]. Nanovláknenné materiály se vyrábějí technikou zvaná *elektrostatické zvlákňování*¹³. Jedná se o fyzikální jev, který byl k výrobě nanovláken použit poprvé v roce 1900. Metody pracující na tomto principu byly o dva roky později patentovány [6].

Výrobní proces využívá elektrostatických sil k utváření jemných vláken z polymerního roztoku nebo polymerní taveniny. Polymerní roztok je roztok makromolekul, které jsou od sebe vzdálené, a každá je obklopena molekulami rozpouštědla. Je využito vysoké napětí, které vytvoří elektricky nabitý proud polymerního roztoku nebo taveniny, se kterým je spojena elektroda vysokého napětí.

Dále dochází ke zvlákňování polymerního roztoku, který může být ve stříkačce, a potom se jedná o elektrostatické zvlákňování kapilárou¹⁴. Nebo se může jednat o elektrostatické zvlákňování z tyčky v případě použití ocelového trnu s roztokem polymeru. Třetí možností je elektrostatické zvlákňování z válečku, který je ponořen v polymerním roztoku.

U zvlákňování kapilárou je vysoké elektrické napětí mezi uzemněným kolektorem a špičkou kapiláry příčinou vzniku tzv. *Taylorova kuželu*, ze kterého jsou uvolňována vlákna. Ta po odpaření rozpouštědla ztuhnou a vytvoří vláknennou strukturu na povrchu kolektoru.

Nanovláknenné materiály se vyznačují velkým měrným povrchem, vysokou porozitou a malou velikostí pórů. K výrobě se používá více než padesát druhů polymerů. Uplatnění je v mnoha oblastech. Nanovláknenné materiály se dají použít ke vzduchové a kapalinové filtraci nebo jako separační membrány. Dále najdou uplatnění v kosmetice nebo v biomedicině (např.

¹³ anglicky *electrospinning*

¹⁴ označuje se také jako *zvlákňovací tryska*

umělé orgány, tkáňové inženýrství, krevní cévy, dýchací masky - roušky). Používají se i u ochranných oděvů, solárních plachet, při aplikaci pesticidů na rostliny nebo také jako nosiče chemických katalyzátorů.

4 Technické a programové prostředky

4.1 Snímací soustava

Nejdůležitější ve kterémkoliv systému počítačového vidění je mít obrazová data, která vhodně reprezentují vyhodnocované objekty, a tudíž obsahují všechny požadované informace. Taková data můžeme označit jako kvalitní vzhledem k požadavkům, které jsou na ně kladeny. Proto je nutné při návrhu snímací soustavy věnovat velkou pozornost výběru jednotlivých komponent a poté vhodnému nastavení celého systému. Při nevhodném nastavení nebo špatném výběru komponent jsou v drtivé většině případů získána méně kvalitní obrazová data. S tím samozřejmě souvisí menší přesnost měření a výstupů ze systému, ale také větší složitost postupů zpracování obrazových dat.

Snímací soustava se skládá obvykle z těchto prvků:

- snímací zařízení (nejčastěji kamera)
- optická soustava (objektiv)
- osvětlovač

4.1.1 Snímací zařízení

V běžných snímacích zařízeních se pro přenos informace využívá optické záření, které představuje část spektra elektromagnetického záření s vlnovými délkami v rozsahu $1\text{ nm} - 1\text{ mm}$. Do oblasti optického záření spadá světlo¹⁵, tedy viditelná část elektromagnetického záření, které je schopné vyvolat zrakový vjem. Podrobněji je celá problematika vysvětlena v [7].

Základním stavebním prvkem snímacího zařízení, kterým je v běžných případech kamera, je optoelektronický snímač nazývaný také jako fotocitlivý senzor. Používají se technologie snímačů CCD¹⁶ a CMOS¹⁷ [8]. Každá technologie má své výhody a nevýhody. CMOS kamery jsou díky integraci snímače na čipu s elektrickými obvody (řídící logika, zesilovače, zdroj hodinového signálu, A/D převodník) jednodušší, kompaktnější, díky integraci mají nízkou spotřebu (oproti CCD může být rozdíl i o jeden řád ve prospěch CMOS)

¹⁵ meze spektrálního rozsahu závisejí na pozorovateli a pohybují se od 380-400 nm do 760-780 nm

¹⁶ Charge Coupled Device

¹⁷ Complementary Metal Oxid Semiconductor

a v neposlední řadě jsou také levnější. Naproti tomu CCD snímače jsou umístovány na desky s plošnými spoji a jsou tedy více prostorově náročné, jsou náročnější na napájení, oproti CMOS jsou dražší. Nejpodstatnější výhodou je ale nižší šum než u CMOS plynoucí z architektury.

Fotocitlivý snímač si lze představit jako množinu fotocitlivých elementů (fotoelementů) umístěných ve čtvercovém rastru (matici). Primárním rozdílem obou technologií je čtení dat z jednotlivých elementů. V případě CMOS se čtení označuje jako náhodné, kdy je možné pomocí adresovacích vodičů (výběrové řádkové a čtecí sloupcové) vyčítat jednotlivé fotoelementy (buňky). Čtení tak probíhá na úrovni jednotlivých buněk. U CCD čtení probíhá sekvenčně pomocí posuvných (transportních) registrů, které představují základ CCD snímačů. U CCD se tedy vyčítají data ze snímače postupně řádek po řádku.

U CMOS se můžeme setkat s pasivními nebo aktivními snímači. Aktivní mají u každé buňky také zesilovač a obvod odstraňující šum. Vykazují tedy menší šum než pasivní snímače, nicméně každý zesilovač nezesiluje úplně stejně, což přispívá k úrovni přítomného šumu. Samotné zesilovače jsou také umístěné blízko fotodiody a dochází tedy k většímu rušení než u CCD, kde jsou zesilovače umístěny mimo samotný čip. U CMOS technologie jsou jako fotoelementy použity fotodiody. Pokud jsou buňky doplněny o zesilovač a obvod odstraňující šum jedná se o aktivní snímače (Active Pixel Sensor), v opačném případě mluvíme o snímačích pasivních (Passive Pixel Sensor). Aktivní CMOS mají díky doplňujícím obvodům každé buňky menší šum než pasivní, nicméně každý zesilovač může zesilovat nepatrně jinak. Další fakt je také ten, že zesilovače jsou umístěny blízko samotných fotodiód, což způsobuje vznik malého rušení i šumu. Významným faktorem ovlivňujícím kvalitu získaného obrazu je také faktor plnění *fill factor*¹⁸, který představuje poměr účinné plochy buňky vůči ploše celkové. Díky již zmíněným obvodům a tranzistorům může mít u konvenčních CMOS *fill factor* hodnotu až 1/4. Tyto části optické záření totiž odráží a neumožní sběr všech dopadajících fotonů na snímač.

Základním stavebním prvkem CCD snímačů jsou již zmíněné posuvné registry. Ty je možno chápat jako sadu MOS kapacitorů umístěných vedle sebe umožňujících transport generovaného elektrického náboje na obvod výstupního nábojového detektoru, který není přímo součástí vlastního snímače (je umístěn na čipu) a zesílení je stejné pro celý snímač, což je výhoda ve srovnání s CMOS technologií. Jako fotocitlivý element může být využito MOS kapacitorů nebo fotodiód s PN přechody.

CCD snímačů existuje více typů. Z hlediska uspořádání se dělí na snímače řádkové a plošné. Řádkové snímače představují fotoelementy uspořádané v řádcích. Existují

¹⁸ česky *faktor plnění*

jednořádkové i víceřádkové snímače. Kamery obsahující tyto snímače se označují jako řádkové kamery a používají se v případech, kdy se scéna pohybuje liniovým posunem. S rychlostí posunu je nutné synchronizovat snímání jednotlivých řádků, jejichž složením získáme reálný obraz scény. Řádkové kamery mohou disponovat velkým rozlišením, a tudíž poskytnout velkou přesnost a hlavně jsou konstrukčně navrženy pro velkou frekvenci snímání (řádková frekvence), a proto využívají vysokorychlostní komunikační rozhraní jako například Camera Link¹⁹. Řádkové snímače mohou obsahovat pro zvýšení řádkové frekvence více posuvných registrů a i více výstupních nábojových detektorů. Proto jsou řádkové kamery vhodné pro snímání scény pohybující se i velkými rychlostmi.

Plošné CCD snímače obsažené v plošných kamerách²⁰ existují v několika modifikacích. Snímače typu Full Frame sensor (FF) využívají jako fotoelementy MOS kapacitory umístěné ve sloupcových posuvných registrech. Z vertikálních sloupcových registrů (VCCD) se generovaný náboj při expozici posouvá do řádkového horizontálního registru (HVCCD), který je připojen na výstupní nábojový detektor. Tyto elementy tedy mají funkci převodu optického záření na generovaný náboj, a poté přenosu náboje za účelem získání digitálních obrazových dat. Tyto snímače využívají téměř celou svojí plochu jako fotocitlivou část. Jsou tedy velmi efektivní a využívají se u snímačů s velkým rozlišením. Nevýhodou FF CCD je nutnost po fázi expozice ve fázi čtení zamezit osvětlení snímače. Pokud na snímač ve fázi čtení dopadá optické záření, dochází k doplňkové expozici, a tudíž k degradaci signálu jevem označovaným jako „smear“. U FF CCD se můžeme setkat se sumačním módem (pixel binning), který v případě slabého osvětlení scény umožňuje sečtení nábojů z více sousedních buněk. Sčítání probíhá na úrovni posuvných registrů a v případě pixel binning 2 x 2 se na jeden pixel skládají čtyři buňky a dochází samozřejmě ke snížení geometrické rozlišovací schopnosti. Výsledné rozlišení je tedy shodné se snímačem, jehož horizontální i vertikální rozlišení by bylo poloviční. U snímačů s velkým počtem fotoelementů může být konstrukce upravena tak, že je snímač rozdělen na více autonomních sekcí, které jsou prakticky samostatnými snímači. Každá sekce tedy obsahuje svůj výstupní nábojový detektor a k ní připojený horizontální posuvný registr.

Snímače TDI (time delay integration) jsou konstrukčně podobné snímačům FF CCD, jejich funkce je ale podobná řádkovým snímačům. Jejich uplatnění se najde tam, kde je nedostatečná doba akumulace určená řádkovou frekvencí snímání a je získán velmi slabý

¹⁹ speciálně navrženo pro oblast počítačového vidění, nejrychlejší konfigurace komunikuje rychlostí 6,8 Gbit/s

²⁰ z označení plošných kamer se z důvodu větší četnosti oproti řádkovým často vypouští slovo označující typ snímače

videosignál. Efektivní doba akumulace je u TDI navýšena tolikrát, kolik je vertikální rozlišení, resp. počet elementů ve VCCD registru.

Dalším typem je FT (frame transfer) snímač, který má svoji polovinu u HCCD registru zakrytou nepropustnou vrstvou, nejčastěji napařeným hliníkem, a tedy neslouží pro akumulaci náboje, ale jako analogová paměť.

Snímače typu IL (interline transfer) využívají pro detekci optického záření fotodiod s PN přechodem, které jsou navázány na VCCD registry. Ty jsou zastíněny vrstvou hliníku a slouží tedy pouze pro přenos generovaného náboje. Při určitém zjednodušení se tyto snímače dají představit jako množina řádkových snímačů doplněných jedním posuvným registrem. Kombinací FT a IL jsou snímače typu FIT (frame interline transfer), které jako fotodetektory používají diody jako IL snímače. Jejich VCCD jsou ale rozděleny do dvou polovin. Jedna je navázána na fotoelementy a druhá slouží jako analogová paměť stejně jako u FT snímačů.

Fotoelementy používané v optoelektronických snímačích nejsou samy o sobě schopné rozlišovat barvu, která je dána vlnovou délkou, ale rozlišují pouze jas. Snímání barevného obrazu je možné řešit několika přístupy. Nejstarší metoda je podobná statistické filtraci, kdy se daná scéna snímá opakovaně. Tentokrát je ale při každém snímání použit barevný filtr. Z výsledných obrazů, kde každý představuje jednu barevnou složku, je potom složen obraz barevný. Jasové hodnoty jednotlivých obrazů se použijí jako hodnoty intenzit příslušné barvy. Nevýhodou tohoto postupu je jeho omezené použití pouze pro statickou scénu.

Další přístup spočívá v umístění barevného filtru příslušné barvy nad každý fotoelement snímače. Jedná se o tzv. Bayerovu masku²¹, ve které mají „zelené“ buňky na základě citlivosti lidského oka dvojnásobné zastoupení oproti modrým a červeným. Takový vzor filtru se označuje jako G-R-G-B²². Z důvodu chybovosti vnímání spektra v některých případech někteří výrobci používají jiné kombinace jako například C-Y-G-M²³ nebo R-G-B-E²⁴. Tento postup snižuje geometrickou rozlišovací schopnost podobně jako sumace u FF CCD.

Barevné snímání lze také realizovat pomocí optického hranolu (beam splitter), který rozdělí barevné spektrum na více částí. Každá část je potom směřována na samostatný senzor. Oproti předchozímu postupu nedochází ke změně rozlišovací schopnosti ve srovnání se snímačem se stejným rozlišením. Zařízení využívající tento způsob jsou ale velmi drahá a jedná se především o profesionální 3CCD kamery.

²¹ někdy také označována jako Bayerova mozaika nebo Bayerův filtr

²² Green – Red - GreenBlue (zelená – červená – zelená - modrá)

²³ Cyan – Yellow – Green - Magenta (azurová – žlutá – zelená - fialová)

²⁴ Red-Green-Blue-Emerald; emerald (smaragd) představuje světle modrou barvu

Poslední způsob se nazývá Foveon X3 [9] a je založen na vlastnostech optického záření, které na základě vlnové délky, která odpovídá barvě, vniká do různé hloubky křemíkové vrstvy. Modrá barva má nejkratší vlnovou délku a proto vniká do nejmenší hloubky, hlouběji zelená a nejhluběji červená, protože má vlnovou délku největší. Ultrafialové záření je zachycováno na povrchu senzoru. Jedná se tedy o určitou analogii s tříčipovým řešením uvedeným výše, v tomto případě jsou ale snímače integrovány do jednoho a není použito optického hranolu.

Z důvodů již zmíněných vlastností CMOS, především ceně, se ve spotřební elektronice využívají snímače typu CMOS. CCD se zase používá v profesionálních aplikacích, kde jsou velké požadavky na kvalitu. V současné době se především kvalitativní rozdíly mezi CCD a CMOS začínají smazávat v důsledku masivních investic do vývoje CMOS za účelem odstranit některé nevýhody.

Jedním příkladem mohou být například BSI²⁵ snímače, které mají změnou konstrukce významně větší aktivní plochu snímače díky umístění kovových obvodů a tranzistorů na opačnou stranu křemíkového substrátu. Problémy, které BSI koncepce přináší, jsou podle současného vývoje úspěšně vyřešeny a oproti konvenčním FSI²⁶ CMOS BSI přináší vyšší fill factor a tudíž i citlivost, větší rychlost, menší rozměry a také v současné době již nižší náklady na výrobu.

Dalším vylepšením CMOS snímačů může být technologie ISOCELL od firmy Samsung. Jedná se o tzv. odizolování jednotlivých buněk snímače fyzickou bariérou a snížení nežádoucích elektrických přeslechů²⁷ o přibližně třicet procent. Výsledkem by měla být vyšší věrnost barev, ostrost a sytost, ale také vyšší kapacita buňky, což zajistí větší dynamický rozsah.

Vedle optických zařízení, která k přenosu informace využívají optické záření, existují i zařízení využívající místo fotonů elektrony. Přesnost měření je závislá na vlnové délce použitého záření a velikost nejmenších pozorovatelných detailů je určena polovinou vlnové délky použitého záření. Urychlené elektrony mají vlnovou délku mnohem menší než je vlnová délka fotonů optického záření a platí pro ni vztah²⁸

$$\lambda = \frac{h}{p} = \frac{h}{\sqrt{2meU}}. \quad (1)$$

Elektronový mikroskop, který místo fotonů používá právě elektrony, umožňuje pozorovat mnohem menší detaily ve srovnání s optickými mikroskopy. Má tedy mnohem vyšší mezní

²⁵ zkratka anglického *back-side illumination*; česky *zadní osvětlení*

²⁶ z anglického *front-side illumination*; česky *přední osvětlení*

²⁷ anglicky *crosstalk*


²⁸ h je Planckova konstanta; p je hybnost ($p = m \cdot v$); m je hmotnost elektronu; e je náboj elektronu; U je urychlovací napětí

rozlišovací schopnost, která je dána minimální vzdáleností dvou ještě rozlišitelných bodů. Místo optické soustavy v podobě soustavy optických čoček, na rozdíl od optického mikroskopu (kapitola 4.1.2), obsahuje elektronový mikroskop elektromagnetické čočky, které jsou v podstatě cívky vytvářející vhodně tvarované magnetické pole.

4.1.2 Optická soustava

Úlohou optické soustavy je vhodně upravit chod optického záření za účelem jeho soustředění na fotocitlivý snímač. Jedná se o zobrazení obrazu snímané scény na zmíněný snímač umístěný na obrazové rovině. Optická soustava je složena z odrazných nebo lámavých ploch a běžně se nazývá objektiv. Uplatňuje se tedy lom na kulové lámavé ploše v případě čočkových objektivů nebo odraz na kulové zrcadlové ploše, který využívají zrcadlové objektivy. Ve videometrii se používají převážně čočkové objektivy.

Nejčastěji používané *normální* objektivy využívají k zobrazení perspektivní projekci. Zorné pole u takového objektivu je komolý kužel. Díky snímači s pravoúhlou fotocitlivou plochou je kužel redukován na pohledový jehlan, jehož vrcholem je ohnisko projekce. Z obrázku 1, na kterém je ukázána geometrie perspektivní projekce, je patrná ztráta prostorové informace.




Obrázek 1: Perspektivní projekce do roviny.

Perspektiva je optický jev, který způsobuje to, že se vzdálený objekt jeví zdánlivě menší než stejně velký blízký objekt. Dále také způsobuje optické zkracování a zužování linií. Zkracování linií je jev, kdy se stejné objekty postavené za sebou do řady zdají blíže u sebe

s rostoucí vzdáleností od pozorovatele. Optické zužování linií se projevuje u více rovnoběžek tím, že se směrem k horizontu opticky zužují, až se zdánlivě setkají v bodě, který se nazývá úběžník.

Z hlediska návrhu optické soustavy, resp. výběru vhodného objektivu, se běžně čočkové (případně zrcadlo - čočkové) objektivu nahrazují tenkou spojnou čočkou za účelem stanovení požadované hodnoty základního parametru, kterým je ohnisková vzdálenost (Obrázek 2).



Obrázek 2: Zobrazení tenkou spojnou čočkou.²⁹

Nahrazením objektivu tenkou spojnou čočkou máme pouze jeden hlavní bod (H splývá s H'), kterým prochází hlavní rovina, která je kolmá na optickou osu. Dále se předpokládá rovnost předmětové ohniskové vzdálenosti (f) a obrazové ohniskové vzdálenosti (f').

Pokud se při snímání změní předmětová vzdálenost, změní se také obrazová vzdálenost. Abychom získali ostrý obraz, je nutné změnit nastavení optické soustavy, konkrétně hodnoty parametru z' . Tomuto úkonu se říká *ostření* a umožňuje ho *výtah* objektivu (v_0), případně *mezikroužek*. Výtah je konstrukční mechanická vlastnost objektivu, která umožňuje měnit hodnotu parametru z' od nuly do výtahu daného konstrukcí objektivu (maximální hodnota). Při z' rovné nule je objektiv zaostřen na nekonečno, maximální hodnota z' odpovídá zaostření na minimální hodnotu předmětové vzdálenosti (minimální ostřicí vzdálenosti), která je jedním ze základních parametrů objektivu.

²⁹ y je velikost předmětu; y' je velikost obrazu; a je předmětová vzdálenost; a' je velikost obrazu; F je předmětové ohnisko; F' je obrazové ohnisko; H je hlavní předmětový bod, který splývá s hlavním obrazovým bodem H'

Pokud potřebujeme zaostřit objektiv na vzdálenost menší než minimální ostřicí, můžeme použít *mezikroužek*. Jedná se o mechanický člen, který se umísťuje mezi objektiv a kameru a hodnotu z' prodlouží o tloušťku mezikroužku (d'_M). Zkrátí se tedy minimální ostřicí vzdálenost, dojde ale také ke ztrátě možnosti ostřit na nekonečno a ostření je možné v odpovídajícím intervalu mezních ostřicích vzdáleností. Při zkrácení hodnoty minimální ostřicí vzdálenosti se zvýší hodnota příčného zvětšení, která je dána poměrem velikosti obrazu k velikosti předmětu (při aplikaci znaménkové konvence jde přesně o absolutní hodnotu příčného zvětšení).

Kromě mezikroužku lze použít *předsádkové čočky*. V tomto případě se již jedná o optický člen (mění chod paprsků optického záření), který se vkládá mezi snímanou scénu a objektiv. Objektiv je nutné zaostřit na nekonečno a snímáný objekt umístit do předmětového ohniska předsádkové čočky. Podobně jako u mezikroužku dochází také ke zvětšení hodnoty příčného zvětšení.

Čočkové objektivy umožňují změnu důležitého parametru *aperturní clony*³⁰. Jedná se o mechanickou (ne optickou) část optické soustavy, která reguluje množství optického záření, které může procházet optickou soustavou. Je realizována pomocí soustavy lamel upevněných na čepech, které jsou ovládány společným prstencem a mají za úkol vytvořit kruhový (v reálu přibližně kruhový) otvor, jehož střed leží na optické ose. Míra regulace clonou se označuje jako *clonové číslo*³¹, které se udává v geometrické řadě s kvocientem $\sqrt{2}$. Změna na následující vyšší clonové číslo znamená dopad polovičního optického výkonu na snímač.

Změnou clonového čísla lze ovlivnit optický jev zvaný *hloubka ostrosti*³². Při ideálním zobrazení se bod umístěný v předmětové vzdálenosti zobrazí do bodu v odpovídající obrazové vzdálenosti, kde je umístěn snímač kamery. Pokud je snímáný objekt umístěný v jiné vzdálenosti, než na kterou je zaostřeno, obraz se reálně vytváří před anebo za snímačem a na snímač se bod zobrazuje v podobě *rozptylového kroužku*³³ a obraz tedy není ostrý. Hodnota průměru rozptylového kroužku definuje maximální míru rozostření, které odpovídají povolené posuny snímaných objektů do největší přední nebo nejmenší zadní předmětové vzdálenosti. Rozsah těchto vzdáleností se přesně označuje *hloubka pole*³⁴. Odpovídající rozsah obrazových vzdáleností se označuje právě jako *hloubka ostrosti*. V umělecké fotografii se tohoto jevu využívá cíleně pro potlačení méně důležitého pozadí a zdůraznění pro diváka důležité části snímané scény. Rozostřené pozadí tak není rušivé a interpretace trojrozměrné (3D) scény

³⁰ často označováno pouze *clona*; anglicky *aperture*

³¹ anglicky *f-number*

³² správněji *hloubka pole*

³³ nazývá se také *kroužek neostrosti*; anglicky *circle of confusion* - COC

³⁴ anglicky *depth of field* – DOF

do dvourozměrného obrazu je srozumitelnější. V technické oblasti je toto ale nežádoucí, a pokud například není nastavení snímací soustavy dostatečně robustní anebo technicky nelze zajistit přesné napolohování snímaného objektu (předmětová vzdálenost se může mírně měnit), je snaha tento jev co nejvíce potlačit. Lze toho dosáhnout zvýšením clonového čísla, čímž se ale snižuje množství optického záření dopadajícího na snímač a nelze ho tedy nastavit libovolně.

Při snímání je potřeba správně nastavit všechny *expoziční parametry* – tedy *expoziční*³⁵. Mezi tyto parametry patří clonové číslo, *expoziční čas*³⁶ a *citlivost*³⁷. Expoziční čas definuje dobu, jak dlouho je snímač vystaven působení optického záření. Stanovuje se pomocí hodnot logaritmické stupnice (odpovídá fyziologickému vnímání světla okem) kdy platí, že sousední hodnota mění dobu a tím i množství optického záření dvojnásobně (větší na dvojnásobek, menší na polovinu). Podobně se chová i změna hodnoty expozičního parametru citlivosti. Při změně na nejbližší vyšší, resp. nižší hodnotu se citlivost zdvojnásobí, resp. sníží na polovinu.

Proto se využívá *expoziční hodnota*³⁸, což je bezrozměrná veličina informující o množství optického záření určená ze všech expozičních parametrů. Stejného množství lze dosáhnout více kombinacemi nastavení, vždy je ale potřeba zvolit tu vhodnou na základě vnějších podmínek. Pro dynamickou scénu nemůžeme nastavit libovolně velkou hodnotu expozičního času, abychom nezískali rozostřený obraz. Pro získání dobré hloubky ostrosti nemůžeme objektiv moc přiclinit (nastavit vysoké clonové číslo), stejně jako nemůžeme libovolně zvyšovat citlivost, díky čemuž se kromě užitečného signálu zesílí i šum.

expoziční čas [s]	změna EV		clonové číslo	změna EV		Citlivost ISO	změna EV
1	0		1,0	0		50	1
1/2	1		1,4	1		100	0
1/4	2		2,0	2		200	-1
1/8	3		2,8	3		400	-2
1/15	4		4,0	4		800	-3
1/30	5		5,6	5		1600	-4
1/60	6		8	6		3200	-5
1/125	7		11	7			
1/250	8		16	8			
1/500	9		22	9			
1/1000	10		32,0	10			
1/2000	11		45,0	11			

Tabulka 1: Určení expoziční hodnoty na základě expozičních parametrů.

³⁵ anglicky *exposure*

³⁶ anglicky *exposure time*, méně přesně se označuje jako *rychlost závěrky* (shutter speed)

³⁷ dle normy se udává v jednotkách ASA, v digitálních fotoaparátech se setkáme s označením ISO

³⁸ anglicky *exposure value* - EV

Kromě objektivů s perspektivní projekcí existují i objektivy s projekcí ortografickou. Takové objektivy nezobrazují scénu s ohniskovou perspektivou, ale s kolmou paralelní projekcí. Takové objektivy se nazývají *telecentrické* a jsou vhodné pro přesné videometrické měření, protože jejich příčné zvětšení nezávisí na předmětové vzdálenosti. Velikost obrazu se tedy nemění z důvodu použití pouze rovnoběžných paprsků s optickou osou. Funkci telecentrického objektivu lze vysvětlit pomocí dvou spojných čoček, kdy obrazové ohnisko přední čočky splývá s předmětovým ohniskem druhé čočky. Umístěním clony do tohoto ohniska je dosaženo potlačení všech paprsků, které nepřicházejí do objektivu rovnoběžně s optickou osou.

Lze zkonstruovat i tzv. *hypercentrický* objektiv, u kterého je pohledový kužel obrácen oproti normálnímu objektivu. Při rostoucí předmětové vzdálenosti se zobrazením hypercentrickým objektivem se objekt jeví jako větší.

Aperturní clona je umístěna u normálního objektivu mezi hlavní rovinu a obrazové ohnisko tenké spojně čočky nahrazující objektiv. Pro telecentrický objektiv je clona v obrazovém ohnisku, u hypercentrického objektivu je clona umístěna mezi obrazové ohnisko a obrazovou rovinu.

Mezi optické soustavy patří také další optické přístroje jako *mikroskop*³⁹ nebo *endoskop*. Endoskop umožňuje přenášet optické záření z uzavřených či jinak nepřístupných míst na snímač nebo k pozorovateli. Téměř vždy bývá doplněn vlastním světelným zdrojem. Pro připojení digitální kamery je nutné využít adaptér. Endoskopy se uplatňují jak v lékařství, tak v technické oblasti v tzv. *endoskopii*. Mikroskop⁴⁰ umožňuje zobrazení s velkým zvětšením⁴¹. Po připojení kamery pomocí adaptéru lze pořídit *mikroskopické snímky*. Díky velkému zvětšení má mikroskop malé zorné pole a také malou hloubku ostrosti. Kromě optického mikroskopu existuje také mikroskop elektronový (kapitola 4.1.1).

Pro přesné videometrické měření je nutné před vlastním snímáním scény provést *kalibraci*. Reálná optická soustava vždy zobrazuje s určitými optickými vadami. Mezi ně patří geometrické zkreslení. To může být dvojího druhu – poduškové nebo soudkové. Kalibrací se rozumí přepočítání matice pixelů na základě jejich přesné pozice v obraze. K tomu se používají *kalibrační masky*. Tu získáme umístěním *kalibrační mřížky* do scény. Jako kalibrační mřížka může být použita pravoúhlá ekvidistantní síť bodů nebo šachovnice se známými rozměry

³⁹ přesně *optický mikroskop*; optický mikroskop je nejběžnější a proto se používá označení pouze *mikroskop*

⁴⁰ české označení je *drobnohled*

⁴¹ běžně se jedná o zvětšení 50x až 1000x; maximální teoretické zvětšení 2000x již naráží na fyzikální omezení v podobě vlnové délky záření

(záleží na konkrétní implementaci). Díky provedení kalibrace je kromě odstranění geometrického zkreslení možné měřit v reálných jednotkách.

Jako součást optické soustavy lze použít i *optického filtru*. Ten se vkládá do cesty optickému záření a mění jeho vlastnosti (směr obvykle ne). Existují například *barevné filtry* upravující chromatickou teplotu zdroje světla, *infračervené filtry*⁴² propouštějící pouze *infračervené záření*⁴³ (nepropouští tedy viditelné světlo) nebo *polarizační filtry*, které propouští pouze záření kmitající v jednom směru a odstraňuje odlesky, a lze s ním dosáhnout věrnější podání barev.

4.1.3 Osvětlení

Velmi důležitou částí snímací soustavy je vhodné nasvícení scény. Za tímto účelem se používají *osvětlovače*, jejichž výběr a případné nastavení vyžaduje zkušenosti a také experimentální ověření. Často je nutné odstínit osvětlení od nežádoucích zdrojů. Toho lze dosáhnout například pomocí fyzického zakrytování nebo využití infračerveného osvětlovače v kombinaci s infračerveným filtrem.

Osvětlovače lze dělit podle základních dvou hledisek:

- světelný zdroj
 - LED osvětlovač
 - zářivkový osvětlovač
 - halogenový osvětlovač
 - laserový osvětlovač, laserová dioda
- princip osvětlovače
 - čelní (přímý) osvětlovač
 - kruhový
 - bodový
 - bodový kolimovaný
 - čarový
 - plošný
 - zadní osvětlovač (backlight)
 - zatemněný osvětlovač (dark-field / low-angle)

⁴² anglicky *infrared filter* - IR

⁴³ část elektromagnetického spektra s vlnovými délkami v rozsahu od 760 nm do 1 mm

- difuzní osvětlovač
 - osvětlovač typu „Dóm“ (dome illuminator / cloudy day)
 - osvětlovač s koaxiálním difuzním světlem

Každý osvětlovač má také svoji chromatičnost. Pro černobílé kamery je nejvhodnější použití monochromatického červeného světla, na které jsou na základě spektrální citlivosti nejcitlivější.

Pomocí čelního osvětlovače můžeme nasnímat povrch objektu. Zadní osvětlovač je zase vhodný pro videometrické měření, protože získáme obrys objektu, nebo umožní zviditelnění neprůhledných částí objektu. Zatemněný osvětlovač se hodí pro účely zviditelnění gravírovaných nebo laserem vypálených značek, protože zvyšuje kontrast tenkých objektů na lesklém povrchu. Osvětlovač typu Dóm lze použít pro snímání objektů pod lesklými a nerovnými povrchy (např. plastové obaly). Osvětlovač s koaxiálním difuzním světlem zdůrazňuje zrcadlové plochy kolmé na optickou osu, a tak je vhodný pro nasvícení například desek plošných spojů.

4.1.4 Parametry snímací soustavy

Při návrhu a realizaci snímací soustavy je nutné jednotlivé součásti v prvním kroku vybírat podle konkrétní aplikace a jejich technických specifikací. Pro výběr kamery je podstatná požadovaná přesnost měření (kapitola 5.1.1). Na základě toho se zvolí požadované rozlišení snímače, případně také jeho formát. V případě požadavku na informaci o barvě objektu je nutno uvažovat vlastnosti jednotlivých metod snímání barevného obrazu (kapitola 4.1.1). Kamera se snímačem s Bayerovou maskou má při srovnatelné ceně s černobílou kamerou nižší geometrickou rozlišovací schopnost, kamery využívající další sofistikovanější metody jsou zase dražší.

Nejdůležitější parametry kamery jsou:

- rozlišení - udává se horizontální i vertikální, nejčastěji v poměru 4:3, souhrnně se uvádí celkový počet pixelů v *MPx*
- formát snímače – udává se v palcích, odpovídá konkrétní horizontální a vertikální velikosti (historicky odvozeno z velikosti ekvivalentního průměru vidikonu, což je starší snímací elektronka)

- snímková frekvence – udává maximální rychlost snímání, uvádí se v jednotkách fps^{44} (u řádkových kamer se udává řádková frekvence v jednotkách lps^{45})
- typ snímače – plošný vs. řádkový, CCD vs. CMOS, barevný vs. černobílý
- komunikační rozhraní – důležité pro určení maximální datové propustnosti (GigE Vision, USB 3.0, Camera Link, FireWire atd.)
- bitová hloubka – počet kvantovacích úrovní (kapitola 5.1.2)
- typ objektivu – C, CS atd.

Při volbě objektivu je nejdříve nutné zvolit typ objektivu (kapitola 4.1.2). Podle technické specifikace kamery je nutné vybrat objektiv⁴⁶. Setkat se můžeme s typy C^{47} , CS^{48} , $M42^{49}$, případně F^{50} . Daný objektiv musí také být kompatibilní s velikostí snímače a měl by podporovat i jeho rozlišení⁵¹.

Základní parametry objektivu:

- upevnění na kameru – C, CS atd.
- typ zobrazení – normální, telecentrický, hypercentrický
- ohnisková vzdálenost – označuje se jako f a udává se v milimetrech, její žádaná hodnota se určí z formátu snímače a velikosti snímání scény, podle ohniskové vzdálenosti⁵² se objektivy dělí na normální, širokoúhlé a teleobjektivy (např. 5 mm)
- základní clonové číslo – určuje použitelnost při malých intenzitách osvětlení, udává se také celý rozsah hodnot clonového čísla (např. $F1,4 - 16C$), popřípadě typ clony (mechanická nebo automatická)
- formát snímače – maximální podporovaný snímač (např. $1/2''$)
- výtah objektivu – objektiv může nebo nemusí obsahovat mechanický výtah, pokud ho nemá, ostření se provádí pomocí mezikroužků
- velikost filtru – pro případné použití filtru je uváděn závit

⁴⁴ z anglického *frames per second*

⁴⁵ z anglického *lines per second*

⁴⁶ v některých případech lze doplněním mezikroužku použít jiný

⁴⁷ přesněji *C-mount*; podstatný parametr zadní dosedací vzdálenost Z_v je 17,52 mm

⁴⁸ přesněji *CS-mount*; stejný závit jako C-mount; Z_v je 12,5 mm

⁴⁹ zadní dosedací vzdálenost je 45,75 mm

⁵⁰ přesněji *F-mount*; vyvinutý firmou Nikon pro jednooké zrcadlovky; bajonetové připevnění; pro velké snímače

⁵¹ pro vysoké rozlišení je vhodné použít *megapixelový* objektiv

⁵² přesně se dělení provádí na základě úhlu záběru

Při výběru velmi podstatné součásti, kterou je osvětlovač, je nutné navázat na konkrétní aplikaci (např. hodnocení povrchu, videometrické měření atd.). Podstatné jsou vlastnosti snímaného objektu, ostatní parametry snímací soustavy a další okolní podmínky. Proto je nutné vhodnost výběru osvětlení téměř vždy ověřit experimentálně (kapitola 4.1.4).

4.2 Programové prostředky

4.2.1 Matlab

MATLAB je vysoce výkonný programovací jazyk od společnosti MathWorks pro technické aplikace [10], [11]. Zahrnuje výpočetní, vizualizační a programovací části, kde jsou problémy a jejich řešení vyjádřeny v matematickém zápisu. Typické využití MATLABu zahrnuje:

- matematické výpočty
- vývoj algoritmů
- získávání dat
- modelování a simulaci
- datovou analýzu a vizualizaci
- vědecké a inženýrské výpočty a grafiku
- vývoj aplikací zahrnujících grafické uživatelské rozhraní

MATLAB je interaktivní systém, jehož základní datovou strukturou je matice, která nevyžaduje nastavení dimenzí. Tento fakt umožňuje řešení mnoha technických problémů zejména těch s maticovou a vektorovou formulací.

Jméno MATLAB vzniklo ze slov Matrix Laboratory (maticová laboratoř). Původně MATLAB vznikl jako interaktivní nadstavba pro usnadnění práce s knihovnami LINPACK a EISPACK umožňujícími práci s maticemi. V dnešní době je MATLAB spojen s knihovnami Lapack a Blas a představuje již mnohem více než jen nadstavbu maticové knihovny.

Vlastností, která patrně nejvíce přispěla k rozšíření MATLABu, je jeho otevřená architektura. Tato vlastnost vedla ke vzniku knihoven funkcí (ve skutečnosti adresáře s *.m a *.mex soubory), nazývaných toolboxy, které rozšiřují použití programu v příslušných vědních a technických oborech. MATLAB je úplný programovací jazyk, což znamená, že uživatelé v něm mohou vytvářet funkce nebo celé toolboxy "šité na míru" pro jejich aplikace. Vlastní funkce se způsobem volání nijak neliší od vestavěných funkcí a jsou uloženy v souborech

v čitelné formě. Navíc jsou takto koncipované funkce snadno přenosné mezi různými platformami, na kterých je MATLAB implementován. Všechny moduly systému doprovází rozsáhlá tištěná i hypertextová on-line dokumentace. Otevřená architektura MATLABu inspirovala mnoho nezávislých firem k vývoji a distribuci vlastních produktů, které buď rozšiřují výpočetní prostředí MATLAB o další knihovny a nástroje nebo zajišťují propojení MATLABu s jinými specializovanými programy.

Další významnou předností programovacího jazyka MATLABu je jeho těsná integrace s jazykem Java. Objekty jazyka Java mohou být přímo použity programem v MATLABu, což umožňuje jednak vytvářet složitá grafická rozhraní s použitím grafických objektů Javy, a jednak využít velkého množství volně dostupných knihoven, které byly v jazyce Java vytvořeny. Kromě toho je možné k MATLABu připojovat také moduly napsané v jazyce C a ve Fortranu.

4.2.2 Image Processing Toolbox

Tato knihovna funkcí, která je součástí MATLABu, představuje velmi rozsáhlou sadu standardních funkcí určených ke zpracování, analýze a vizualizaci obrazu v podobě digitálních obrazových dat [27]. Pomocí knihovnických funkcí je možné provádět například segmentaci, geometrické transformace, redukci šumu, filtraci, videometrické měření nebo také vyhledávání definovaných objektů. Obrazová data je možné použít z řady podporovaných obrazových formátů. Některé funkce jsou z hlediska vykonávání vícevláknové a plně tedy využívají vícejádrové a víceprocesorové počítače.

4.2.3 LabVIEW

LabVIEW je vývojové prostředí od firmy National Instruments (NI). Název LabVIEW (LV) vlastně představuje zkratku vycházející z popisu jeho vlastností – Laboratory Virtual Instruments Engineering Workbench⁵³. Základem je grafický programovací jazyk označovaný jako programovací jazyk G. Programy vytvořené v LabVIEW se nazývají VI⁵⁴. Každé VI se skládá ze dvou částí: Front Panelu (čelní panel), který je vizuální částí VI a Block Diagramu (blokové schéma), který obsahuje grafický programový kód VI [12], [13]. Vykonávání programu v LabVIEW probíhá jiným způsobem než ve vývojovém prostředí postaveném

⁵³ v českém překladu znamená „laboratorní pracoviště virtuálních nástrojů“

⁵⁴ zkratka anglického *Virtual Instrument* (virtuální přístroj)

na textovém programovacím jazyku. Pokud srovnáme vývojové prostředí od firmy National Instruments LabVIEW a LabWindows/CVI (kapitola 4.2.4) z hlediska logiky vykonávání programu, v LabVIEW se program vykonává na základě řízeného toku dat⁵⁵ na rozdíl od sekvenčního vykonávání v LabWindows/CVI. Z toho také plyne přirozený paralelismus v grafickém programování v LabVIEW umožňující jednoduchou realizaci paralelních programových větví.

4.2.4 LabWindows/CVI

LabWindows/CVI⁵⁶ (CVI) je vývojové prostředí od firmy National Instruments založené na programovacím jazyku ANSI C. První verze byla vydána pod názvem LabWindows již v roce 1987 pro operační systém DOS. Později bylo prostředí přepracováno pro operační systém Microsoft Windows. Díky skupině doplňků v podobě knihoven se jedná o nástroj určený k vývoji plnohodnotných aplikací. K vytvořenému programu lze po kompilaci také vygenerovat instalační sadu obsahující samotný program včetně dalších souborů (např. konfigurace nebo nápověda) ale také i instalační soubory knihoven.

4.2.5 NI Vision Development Module

NI Vision Development Module (VDM) je velmi obsáhlá sada softwarových nástrojů pro zpracování obrazových dat od firmy National Instruments. Obsahuje jak základní tak velmi pokročilé funkce obrazové analýzy a lze ji tedy využít nejen pro relativně rychlý a jednoduchý návrh a vývoj průmyslových aplikací, ale také pro vývoj pokročilých programů s vlastními sofistikovanějšími algoritmy. Velkou výhodou VDM je nativní podpora jak vývojových nástrojů LabVIEW a LabWindows/CVI od firmy National Instruments, tak dalších vývojových prostředí postavených na programovacích jazycích C, C++, C# a Visual Basic .NET. Součástí VDM je NI Vision Assistant (VA), který představuje jednoduchý a rychlý nástroj pro návrh jednodušších algoritmů zpracování obrazu. VA obsahuje funkci pro export vyvinutých a ověřených algoritmů do grafického programovacího jazyka vývojového prostředí LabVIEW, zdrojového kódu programovacího jazyka C nebo .NET kódu (C# nebo VB.NET).

⁵⁵ anglicky se označuje jako *data flow model*

⁵⁶ zkratka CVI znamená C pro virtuální instrumentaci (C for Virtual Instrumentation)

4.2.6 NI Vision Acquisition Software

NI Vision Acquisition Software (VAS), softwarový produkt od firmy National Instruments, představuje ovladače umožňující použití velké množství hardwaru z oblasti obrazové snímací techniky. Podporovány jsou digitální kamery komunikující přes rozhraní, jako jsou GigE Vision⁵⁷, IEEE 1394⁵⁸ nebo USB⁵⁹. Dále jsou obsaženy ovladače podporující frame grabbery, Vision systémy (např. Compact Vision systémy) a inteligentní kamery (Smart Cameras) od firmy NI. Dále je také obsažena podpora pro méně rozšířené řešení v podobě analogových kamer nebo vysokorychlostního rozhraní Camera Link.

⁵⁷ jedná se o standard vycházející z Gigabit Ethernetu využívající UDP komunikační protokol

⁵⁸ někdy označováno jako FireWire, existuje v několika verzích lišících se rychlostí

⁵⁹ rozšířená sběrnice pro připojení periférií, verze USB 3.0 disponuje přenosovou rychlostí 5 Gbit/s

5 Teoretické rozbory

Pojem obraz lze definovat a chápat ze dvou hledisek. Prvním z nich je hledisko fyziologické, jedná se tedy o zrakový vjem. Tím druhým je potom obraz získaný pomocí technických prostředků. Takto získaný obraz představuje obrazová data, která lze po jejich získání zpracovat opět pomocí dalších technických prostředků za účelem získání požadovaných informací v obraze obsažených.

Problematika zpracování obrazu nachází v současné době poměrně široké praktické uplatnění v mnoha oborech. Ke studiu lze využít například zdroje [14], [15], [16], [17], [18] nebo [19], ze kterých bylo čerpáno.

5.1 Digitalizace obrazu

Čidla pro vstup obrazové funkce jsou většinou zdrojem spojitého signálu a pro počítačové zpracování tedy musíme získat její digitální podobu. Digitalizace obrazu spočívá ve *vzorkování* v matici $M \times N$ bodů a v *kvantování* spojitě jasové úrovně každého vzorku do k intervalů. Díky kvantování nabývá jasová funkce celočíselných hodnot. Čím jemnější je vzorkování (čím větší je M a N) ve vzorkovací matici a čím jemnější je kvantování, tím lépe se digitální reprezentace přiblíží původnímu spojitému obrazovému signálu.

5.1.1 Vzorkování

Nejdříve je třeba určit interval vzorkování (vzdálenost mezi nejbližšími vzorkovacími body v obraze). Podle vzorkovacího teorému⁶⁰ musí být v případě jednorozměrných signálů vzorkovací frekvence větší než dvojnásobek nejvyšší harmonické frekvence obsažené ve vzorkovaném signálu a platí tedy vztah⁶¹

$$f_s > 2f_{\max} . \quad (2)$$

⁶⁰ Shannonův teorém (Nyquistův teorém, Kotělnikovův teorém, Nyquistův-Shannonův teorém, Shannonův-Nyquistův-Kotělnikovův teorém)

⁶¹ f_s je vzorkovací frekvence (s je zkratka pro *sample* což je anglicky vzorek), f_{\max} je frekvence nejvyšší harmonické složky ve vzorkovaném signále

V případě obrazu se vhodněji stanovuje interval vzorkování, který musí být tedy menší než polovina rozměru nejmenších pozorovatelných detailů v obraze. Obrazový signál je dvourozměrný a to tedy odpovídá více než čtyřem vzorkům na nejmenší pozorovatelný detail.

Dále je třeba určit plošné uspořádání bodů pro vzorkování (výběr vzorkovací mřížky).

Hexagonální mřížka je výhodná pro ekvidistantnost, protože je ale její implementace do digitální techniky složitější, používá se nejčastěji mřížka čtvercová. Ta se technicky snadno realizuje a odpovídá reprezentaci obrazu pomocí pravoúhlé matice.

Jednomu vzorkovacímu bodu odpovídá v digitalizovaném obraze obrazový element nazývaný pixel⁶². Po uspořádání do vzorkovací mřížky pokrývají pixely celý digitalizovaný obraz.

5.1.2 Kvantování

Amplituda ve vzorkovaném obraze musí být pro počítačové zpracování vyjádřena jako digitální údaj.

Většina systémů pro digitální zpracování obrazu používá kvantování do k stejných intervalů. Jestliže je pro reprezentaci informace o obrazovém elementu použito b bitů, je počet jasových úrovní $k = 2^b$. U šedotónových obrazů se nejčastěji používá osm bitů na pixel. Setkat se ale můžeme i s vícebitovou hloubkou. Binární obrazy reprezentují informaci o obrazovém bodě jedním bitem. Jedničky označují objekty, nuly pozadí.

Největším problémem je vznik falešných obrysů. To se stává při kvantování do příliš malého počtu jasových úrovní. Pro člověka tento jev začíná být patrný, je-li počet úrovní jasu menší než 50 (asi tolik úrovní je člověk schopen v monochromatickém obraze rozlišit). Částečným řešením je tzv. nelineární kvantování, při kterém se zvětšuje rozsah nejčastěji zastoupených intervalů jasu v obraze.

⁶² z anglického *picture element*

5.1.3 Kvalita obrazu

Při snímání a zpracovávání obrazu dochází k jeho degradaci a obraz tedy může obsahovat různé nežádoucí poruchy, tzv. *šum*.

Šum se většinou popisuje jeho pravděpodobnostními charakteristikami. Idealizovaný šum, ve kterém jsou rovnoměrně zastoupeny všechny frekvence, se nazývá *bílý šum* a představuje nejhorší možnou degradaci obrazu.

Při přenosu obrazu vzniká v přenosovém kanále šum, který je obvykle na obrazovém signálu nezávislý. Takové poruchy se označují jako *aditivní šum* a lze je popsat vztahem

$$f(x, y) = g(x, y) + v(x, y), \quad (3)$$

kde šum v a vstupní obraz g jsou nezávislé veličiny. Ovšem v mnoha případech závisí velikost šumu na velikosti obrazového signálu. Je-li úroveň šumu dostatečně velká vzhledem k užitečnému signálu, platí

$$f = g + v \cdot g = g \cdot (1 + v) \approx g \cdot v. \quad (4)$$

Model daný předchozím vztahem popisuje *multiplikativní šum*.

Není-li počet jasových úrovní dostatečně vysoký, objeví se *kvantizační šum*.

V binárních obrazech se vlivem šumu v oblastech objektů (reprezentovaných bílými body) objevují body černé a naopak. Takové poruchy se označují jako *šum typu pepř a sůl* nebo také *impulsní šum*.

5.2 Předzpracování obrazu

Jako předzpracování se označují společné operace s obrazem na nízké úrovni abstrakce. Cílem předzpracování je potlačit šum vzniklý při přenosu a digitalizaci obrazu, odstranit zkreslení dané vlastnostmi snímacího zařízení nebo potlačit či zvýraznit další rysy obrazu důležité pro další zpracování [20].

5.2.1 Bodové jasové transformace

Transformace hodnot jasu se dělí do dvou skupin, kterými jsou jasové korekce a modifikace jasové stupnice. U jasových korekcí závisí jas v bodě výstupního obrazu na jasu odpovídajícího bodu ve vstupním obraze (a případně na jasu jeho malého okolí). U modifikace

jasové stupnice je jen určitá hodnota jasu ve vstupním obraze transformována na jinou výstupní hodnotu, a to bez ohledu na polohu v obraze.

5.2.1.1 Jasové korekce

Snímací a digitalizační zařízení má mít v ideálním případě stejnou citlivost bez ohledu na umístění bodu v obraze, což ovšem nebývá v praxi někdy splněno. V optických soustavách je obvykle světlo procházející dále od optické osy více zeslabováno. Zdrojem poruch je i nerovnoměrné osvětlení.

Jsou-li tyto poruchy systematické, lze je zmírnit jasovými korekcemi na základě znalosti odchylky citlivosti každého bodu obrazu od ideální převodní charakteristiky. Nejčastěji dochází ke zkreslení obrazu multiplikativním koeficientem $e(i, j)$. Pro každý bod původního obrazu $g(i, j)$ získáme na výstupu zkreslený bod $f(i, j)$ podle

$$f(i, j) = e(i, j)g(i, j). \quad (5)$$

Pak můžeme systematické chyby korigovat podle vztahu

$$g(i, j) = \frac{f(i, j)}{e(i, j)} = \frac{c \cdot f(i, j)}{f_c(i, j)}, \quad (6)$$

kde c je konstantní jas obrazu, po nasnímání a digitalizaci označený $f_c(i, j)$. Tato korekce chyb platí pro stálé snímací podmínky.

5.2.1.2 Modifikace jasové stupnice

U jasových korekcí závisí jas v bodě výstupního obrazu pouze na jasu bodu na vstupu se stejnými plošnými souřadnicemi. U modifikací jasové stupnice je jen určitá hodnota jasu ve vstupním obraze transformována na jinou výstupní hodnotu, a to bez ohledu na pozici v obraze.

Obvyklými transformacemi jasové stupnice jsou *negativ*, *změna kontrastu* a *prahování*. Tyto transformace se poměrně snadno technicky realizují [27].

Transformační vztah pro zvyšování kontrastu se nejčastěji hledá metodou *ekvalizace histogramu*. Ve výsledném vyrovnaném histogramu jsou jednotlivé jasové úrovně zastoupeny zhruba stejně četně. Ekválizace zvýší kontrast pro úrovně blízko maxim histogramu a sníží v okolí minim.

5.2.2 Lokální předzpracování

Metody lokálního předzpracování, využívající pro výpočet jasů bodu ve výstupním obraze jen lokálního okolí odpovídajícího vstupního bodu, se dají rozdělit na dvě skupiny: vyhlazování a gradientní operace.

Vyhlazování obrazu vede k potlačení vyšších frekvencí obrazové funkce. Výsledkem je potlačení náhodného šumu, ale dochází také k vyhlazování ostatních náhlých změn jasové funkce, jako jsou ostré čáry a hrany nesoucí významnou informaci.

Gradientní operace a s nimi související ostření obrazu vedou naopak ke zdůraznění vyšších frekvencí. Současně jsou zvýrazněny ty obrazové elementy, ve kterých se obrazová funkce náhle mění. Výsledkem je zvýraznění hran v obraze, ale dochází také ke zvýraznění šumových bodů.

5.2.2.1 Filtrace

Jako filtrace se označuje skupina transformací, které převádějí hodnoty jasů vstupního obrazu na jiné jasové hodnoty výstupní, s cílem zvýraznit nebo potlačit některé jeho vlastnosti. Častým cílem filtrace je vyhlazování šumu v obraze.

Obyčejné průměrování filtruje obraz tak, že bodu přiřadí aritmetický průměr jasů bodů obdélníkového okolí. Potlačí se tak skvrny šumu menší, než je nejmenší významný detail v obraze. Nevýhodou obyčejného průměrování je rozmazávání hran v obraze, proto se tato technika většinou používá jako pomocná pro výpočet střední hodnoty jasů nebo jeho rozptylu v daném bodě. Tohoto výsledku pak využívají propracovanější filtrační metody, jako je *OS filtrace* (order statistic) nebo metoda *rotující masky*, která podle homogenity jasů nachází k filtrovanému bodu tu část okolí, ke které bod pravděpodobně patří.

5.2.2.2 Detektory hran

Místa v obraze kde se náhle mění hodnota jasů se označují jako hrany [30]. Hrana v obraze je dána vlastnostmi obrazového elementu a jeho okolí. Je to vektorová veličina a je určena tím, jak náhle se mění hodnota obrazové funkce $f(x, y)$. K matematickému popisu se používá parciálních derivací, které jsou určeny pro vyjádření změn funkce dvou proměnných. Změnu funkce udává její gradient, vektorová veličina ∇ , určující směr největšího růstu funkce

(směr gradientu) a strmost tohoto růstu (velikost, modul gradientu). Hranami jsou potom pixely s velkým modulem gradientu, který je pro spojitou funkci n proměnných určen jako

$$\nabla f(x_1, \dots, x_n) = \left(\frac{\partial f}{\partial x_1}, \dots, \frac{\partial f}{\partial x_n} \right). \quad (7)$$

Pro spojitou obrazovou funkci $f(x, y)$ jsou velikost gradientu $|\nabla f(x, y)|$ a směr gradientu ψ dány vztahy

$$|\nabla f(x, y)| = \sqrt{\left(\frac{\partial f}{\partial x} \right)^2 + \left(\frac{\partial f}{\partial y} \right)^2}, \quad (8)$$


$$\Psi = \arctan\left(\frac{\partial f}{\partial x} / \frac{\partial f}{\partial y}\right), \quad (9)$$

kde Ψ je úhel (v radiánech) mezi souřadnou osou x a radiusvektorem k bodu (x, y) .

Pokud nás zajímají hrany bez ohledu na jejich směr lze použít všesměrový lineární Laplaceův operátor Laplacián ∇^2 . Tento operátor vychází z druhých parciálních derivací jak je patrné ze zápisu. Pro monotónně rostoucí jasovou funkci f v příslušném okolí je Laplacián nulový tam, kde je velikost gradientu $|\nabla|$ maximální.

$$\nabla^2 f(x, y) = \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2}. \quad (10)$$

Hrany nalezené v obraze lokálními operátory se někdy používají pro hledání hranic objektů. Pokud je objekt tvořen oblastí homogenního jasu, jsou body hranice právě pixely s vysokou hodnotou gradientu. Pixely, které tvoří hrany (hranové pixely), jsou spojovány do hranic, a proto se směr hrany definuje jako kolmý na směr gradientu, jak je patrné z obrázku 3.



Obrázek 3: Hrana v obraze.

Hrany se dají třídit podle jasového profilu, který je jednorozměrný a je určován ve směru gradientu.

Gradientních operátorů lze použít i pro ostření obrazu. Jeho cílem je získat strmější hrany v obraze. Gradientní operátory udávající strmost obrazové funkce můžeme rozdělit do tří kategorií. První skupina aproximuje derivace obrazové funkce pomocí diferencí realizovaných diskretní konvolucí. Operátory invariantní vůči rotaci se realizují jedinou konvoluční maskou (např. Laplaceův operátor). Operátory, které aproximují první derivaci, používají několik masek. Směr gradientu se odhaduje hledáním té masky, která odpovídá největší velikosti gradientu. Například Robertsův operátor, Sobelův operátor, Robinsonův, Kirschův a Prewittové. Druhá skupina operátorů je založena na hledání hran v místech, kde je druhá derivace obrazové funkce nulová. Mezi tyto operátory se řadí například operátor Marra a Hildrethové nebo Cannyho hranový detektor. Třetí skupina operátorů se snaží lokálně aproximovat obrazovou funkci poměrně jednoduchým parametrickým modelem.

Některé operátory se dají vyjádřit pomocí konvoluční masky, která je potom použita pro diskretní konvoluci dvojrozměrných signálů (2D konvoluce) podle vztahu

$$g(x, y) = \sum_{(i,j)} \sum_{\in O} h(x-i, y-j) f(i, j), \quad (11)$$

kde $f(x,y)$ je vstupní obraz, $g(x,y)$ je výstupní obraz a $h(x,y)$ je konvoluční maska.

Každá integrální transformace (např. Laplaceova, Fourierova, Hilbertova) je speciálním případem konvoluce [15]. Pokud na spojitý signál $x(t)$ působí systém definovaný impulzní odezvou $h(t)$, je potom konvoluce $y(t)$ vyjádřena vztahem

$$y(t) = \int_{-\infty}^{+\infty} x(\tau) h(t - \tau) d\tau. \quad (12)$$

Tento vztah představuje základní vztah spojitě konvoluce jednorozměrných funkcí.

Velmi jednoduchý Robertsův operátor používá okolí reprezentativního bodu o velikosti 2x2 a jeho konvoluční masky jsou

$$h_1 = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix}, \quad h_2 = \begin{bmatrix} 0 & 1 \\ -1 & 0 \end{bmatrix}. \quad (13)$$

Hlavní nevýhodou tohoto operátoru je značná citlivost na šum vyplývající z použití malého okolí.

Konvoluční masky Laplaceova operátoru pracují již v okolí o velikosti 3x3 a jejich základní tvar pro 4-okolí a 8-okolí je tento

$$h_4 = \begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix}, \quad h_8 = \begin{bmatrix} 1 & 1 & 1 \\ 1 & -8 & 1 \\ 1 & 1 & 1 \end{bmatrix}. \quad (14)$$

Existuje i verze Laplaceanu s větší vahou pixelů blíže reprezentativnímu bodu masky. V tomto případě už ale neplatí invariantnost vůči otočení.

Mezi operátory aproximující první derivaci patří operátor Prewittové. Gradient je odhadován v okolí 3x3 pro osm směrů. Vybrána je jedna maska z osmi, a to ta, které odpovídá největší modul gradientu.

$$h_1 = \begin{bmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix}, h_2 = \begin{bmatrix} 0 & 1 & 1 \\ -1 & 0 & 1 \\ -1 & -1 & 0 \end{bmatrix}, h_3 = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix}, \dots h_8 \quad (15)$$

Je možné vytvářet i masky s podrobnějším směrovým rozlišením, které jsou potom větší.

Operátorem, který se často používá pro detekci vodorovných a svislých hran je Sobelův operátor, jehož masky jsou

$$h_1 = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix}, h_2 = \begin{bmatrix} 0 & 1 & 2 \\ -1 & 0 & 1 \\ -2 & -1 & 0 \end{bmatrix}, h_3 = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}, \dots h_8 \quad (16)$$

Nevýhodou operátorů aproximujících derivace diferencemi v malém okolí je značná závislost jejich chování na zpracovávaném obrázku. Závislost na zvoleném měřítku a citlivost na šum jsou také značné.

Na základě tohoto byla formulována Marrova teorie, která měla za cíl vytvořit matematický model detekce skokových hran na základě neurofyzilogického měření na sítnici oka. V místě hrany nabývá první derivace obrazové funkce svého maxima. Tato teorie vychází z derivace druhé. V místě hrany prochází druhá derivace obrazové funkce nulou. Použití druhé derivace místo první je vhodnější, protože maximum u derivace první je velmi často ploché.

K robustnímu odhadu druhé derivace je použito konvoluce s lineárním vyhlazujícím filtrem, jehož koeficienty v konvoluční masce odpovídají 2D gaussovskému rozložení a je nazýván jako Gaussián

$$G(x, y, \sigma) = e^{-\frac{x^2+y^2}{2\sigma^2}}. \quad (17)$$

Parametry x a y jsou souřadnice v obraze a σ je střední kvadratická odchylka, která říká, na jak velkém okolí filtr pracuje. Pro odhad druhé derivace je použit Laplacean ∇^2 . Potom tedy dostaneme

$$\nabla^2(G(x, y, \sigma) * f(x, y)). \quad (18)$$

Tento postup je označován jako *LoG operátor* (angl. Laplacian of Gaussian). Protože použité operace jsou lineární, můžeme zaměnit pořadí derivace a konvoluce. Tím docílíme nezávislosti obrazu, respektive obrazové funkce, na derivaci Gaussiánu $\nabla^2 G$ a můžeme napsat

$$\nabla^2 (G(x, y, \sigma) * f(x, y)) = (\nabla^2 G(x, y, \sigma)) * f(x, y) \quad (19)$$

Hodnoty derivace Gaussiánu poté můžeme spočítat analyticky. Výsledkem je konvoluční maska, které se říká mexický klobouk.

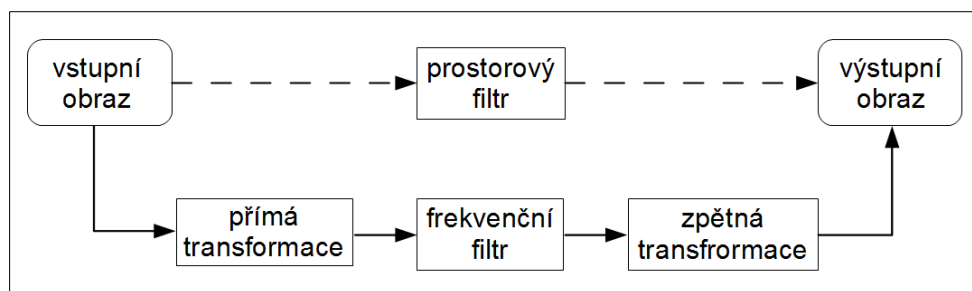
Nevýhodou operátorů používajících konvoluční masky je závislost jejich chování na daném obrázku. Velikost zvolené masky musí odpovídat velikosti detailů v obrázku. Tímto neduhem netrpí Cannyho hranový detektor [21], který byl navržen na principu různých rozlišení a hledání nejlepšího z nich. Jeho základní myšlenkou je hledání hrany filtrem. Návrh tohoto filtru byl řešen jako úloha variačního počtu. Byla také formulována tři kritéria, jejichž splnění zaručuje optimalitu detektoru. Kritéria požadují, aby všechny významné hrany byly detekovány, aby na žádnou hranu nebyla vícenásobná odezva, a aby rozdíl mezi skutečnou a nalezenou hranou byl minimální.

5.3 Integrovní transformace

Filtry mají velkou důležitost v oblasti zpracování signálů. V případě zpracování obrazu budeme na vstupu i výstupu filtru uvažovat dvojrozměrný signál (obraz). V případě uvažování lineárních filtrů lze filtraci rozdělit následujícím způsobem (obrázek 4):

- Filtrace v prostorové oblasti (u jednorozměrných signálů se jedná o filtraci v časové oblasti) obraz zpracuje jako lineární kombinaci vstupního obrazu s koeficienty filtru. Jako matematický nástroj je použit operátor konvoluce. V obrázku 4 je tento postup znázorněn čárkovaně.
- Filtrace ve frekvenční oblasti vyžaduje nejprve obraz převést do *frekvenční reprezentace*. Poté je aplikován frekvenční filtr a získaný výsledek je pomocí inverzní lineární integrovní transformace převeden zpět do prostorové oblasti a je získán upravený obraz. Možných transformací je více, velmi známou je *Fourierova transformace*⁶³.

⁶³ označována zkratkou *FT*; anglicky *Fourier transform*



Obrázek 4: Filtrace obrazu v prostorové nebo frekvenční oblasti.

Fourierova transformace představuje vyjádření časově závislého signálu pomocí harmonických signálů [32]. K těm patří například funkce sinus nebo cosinus, což jsou funkce komplexní exponenciály. Transformace slouží k převodu signálu mezi časovou a frekvenční oblastí. Je vhodná pro periodické signály a základní vztah přímé Fourierovy transformace pro spojitý signál $f(t)$ je

$$F(\omega) = \mathcal{F}\{f(t)\} = \int_{-\infty}^{+\infty} f(t)e^{-2\pi i\omega t} dt, \quad (20)$$

kde ω představuje kmitočet a $2\pi\omega$ je úhlová frekvence. Pro zpětný převod slouží *inverzní Fourierova transformace*⁶⁴, která je dána vztahem

$$f(t) = \mathcal{F}^{-1}\{F(\omega)\} = \int_{-\infty}^{+\infty} F(\omega)e^{2\pi i\omega t} d\omega. \quad (21)$$

Základním stavebním prvkem Fourierovy transformace je vztah mezi goniometrickými funkcemi a komplexní exponenciálou známý jako *Eulerův vzorec*

$$e^{i\omega} = \cos(\omega) + i \sin(\omega). \quad (22)$$

K převodu diskretních signálů do frekvenční oblasti se používají modifikace Fourierovy transformace - *Fourierova transformace diskretních signálů*⁶⁵ a *diskretní Fourierova transformace*⁶⁶. Vztah pro přímou Fourierovu transformaci diskretních signálů získáme ze vztahu pro přímou Fourierovu transformaci (20), pokud nahradíme integrál sumou.

Pokud se signály zpracovávají pomocí číslicových obvodů, operuje se s konečnými počty hodnot v časové i frekvenční oblasti. Signály mají v obou oblastech stejný počet vzorků a při aplikaci přímé i zpětné transformace se považují za periodické.

⁶⁴ označována *IFT*

⁶⁵ označována jako *FTD* (*Fourier transform of discrete signals*) nebo *DTFT* (*Discrete-time Fourier transform*)

⁶⁶ označována *DFT* (*Discrete Fourier transform*)

Přechodem z časové do frekvenční oblasti mezi diskrétními signály $f[n]$ a $F[k]$ jsou pro diskrétní Fourierovu transformaci definovány vztahy

$$F[k] = \frac{1}{N} \sum_{n=0}^{N-1} f[n] e^{-i\frac{2\pi}{N}nk}, \quad k = 0, 1, 2, \dots, N-1, \quad (23)$$

$$f[n] = \sum_{k=0}^{N-1} F[k] e^{i\frac{2\pi}{N}nk}, \quad n = 0, 1, 2, \dots, N-1. \quad (24)$$

Vztah (23) představuje přímou verzi transformace (DFT), vztah (24) verzi inverzní (IDFT). Převody mezi signály lze značit pomocí zápisů

$$f[n] \leftrightarrow F[k], \quad (25)$$

$$f[n] \xrightarrow{DFT} F[k], \quad (26)$$

$$F[k] \xrightarrow{DFT^{-1}} f[n]. \quad (27)$$

Z důvodu vysoké výpočetní náročnosti transformace je možné výpočet diskrétní Fourierovy transformace realizovat pomocí *rychlé Fourierovy transformace*⁶⁷. Základní idea, která sníží počet potřebných operací, využívá periodičnosti a symetrie komplexní exponenciály a převádí posloupnosti délky N dle (23) na součet dvou posloupností s poloviční délkou, kdy jedna posloupnost obsahuje pouze sudé členy a druhá pouze liché členy.

Pro obrazy, obecně dvourozměrné signály, je nutné použít dvourozměrnou Fourierovu transformaci. Vztah dvourozměrné přímé diskrétní Fourierovy transformace je

$$F[k, l] = \frac{1}{MN} \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} f[m, n] e^{-2\pi i \left(\frac{mk}{M} + \frac{nl}{N} \right)}, \quad (28)$$

$$k = 0, 1, \dots, M-1, \quad l = 0, 1, \dots, N-1.$$

Pro zpětný převod inverzní transformací je dán vztah

$$f[m, n] = \sum_{k=0}^{M-1} \sum_{l=0}^{N-1} F[k, l] e^{2\pi i \left(\frac{mk}{M} + \frac{nl}{N} \right)}, \quad (29)$$

$$m = 0, 1, \dots, M-1, \quad n = 0, 1, \dots, N-1.$$

⁶⁷ označení *FFT*; anglicky *Fast Fourier transform*

5.4 Segmentace

Úkolem segmentace je rozdělit obraz do částí, které mají souvislost s předměty nebo oblastmi reálného světa zachyceného na obraze [25], [33].

Segmentace může být buď *kompletní*, kdy výsledkem je soubor vzájemně se nepřekrývajících oblastí, které jednoznačně odpovídají objektům vstupního obrazu, nebo vytvořené segmenty nemusí přímo souhlasit s objekty obrazu, případně se překrývají, pak se jedná o *částečnou segmentaci*.

5.4.1 Segmentace prahováním

Prahování je nejjednodušší segmentační postup. Vychází ze skutečnosti, že mnoho objektů nebo oblastí obrazu má konstantní odrazivost či pohltivost povrchu. Pak se může využít určená jasová konstanta - *práh* - k oddělení objektů od pozadí. Vzhledem k nenáročnosti výpočtu je prahování nejrychlejší segmentační metoda, lze ji provádět v reálném čase.

Prahování je tedy transformace vstupního obrazu f na výstupní binární obraz g daná vztahem

$$g(i, j) = 1 \text{ pro } f(i, j) \geq T, \quad g(i, j) = 0 \text{ pro } f(i, j) < T, \quad (30)$$

kde T je předem určená konstanta (práh), $g(i, j)=1$ pro obrazové elementy náležející objektům, $g(i, j)=0$ pro elementy pozadí (nebo naopak).

5.4.1.1 Metody určování prahu

Klíčovým úkolem při segmentaci prahováním je určení vhodného prahu. Hodnoty prahu lze určovat interaktivně nebo metodami automatického určování prahu.

Procentní prahování využívá apriorní znalosti poměru ploch objektů a pozadí. Víme-li, že objekty zaujímají $1/p$ plochy obrazu, na základě histogramu snadno určíme takovou hodnotu prahu T , aby právě $1/p$ plochy měla úroveň jasu menší než T .

Složitější metody se opírají o analýzu tvaru histogramu.

5.4.2 Segmentace na základě detekce hran

Segmentace na základě detekce hran vychází ze skutečnosti, že hranice oblastí v obraze se skládají z hran, které jsou nalezeny aplikací některého z hranových operátorů. Takto nalezené hrany označují místa v obraze, kde dochází k jisté nespojitosti - obvykle v hodnotě jasu, nebo v barvě či textuře.

Ovšem obraz, který vznikne aplikací hranového operátoru, je jako výstup segmentace ve své prvotní podobě téměř nepoužitelný. Proto po detekci hran následuje další zpracování, které tyto hrany spojuje do řetězců lépe odpovídajících původní hranici.

Nejčastějším problémem hranových segmentačních metod je výskyt hran v místech, kde není skutečná hranice, a naopak absence hran tam, kde hranice ve skutečnosti probíhá.

Nejčastěji používanými metodami jsou *prahování obrazu hran*, kdy se nevýznamné hrany vzniklé vlivem šumu odstraňují prahováním vhodným prahem, *sledování hranice*, jejímž cílem je určit vnitřní hranice všech oblastí obrazu, nebo *heuristické sledování hranice*, kdy se využívá znalosti určitých vlastností hranice. V případě, že obraz obsahuje předměty, jejichž tvar a velikost jsou známy, chápeme segmentaci jako úlohu nalezení daného předmětu v obraze a lze použít *Houghovu transformaci* (viz. kapitola 5.9), která vychází ze vzorového tvaru hledané hranice.

5.4.3 Segmentace narůstáním oblastí

Metoda narůstání oblastí je výhodná v obrazech se šumem, v nichž se hranice určují zvlášť obtížně.

Základní myšlenkou této metody je rozdělit obraz do maximálních souvislých oblastí tak, aby byly z hlediska zvoleného způsobu popisu homogenní. Kritériem homogenity mohou být jasové vlastnosti nebo komplexnější způsoby popisu, jako je například textura, nebo dokonce sémantická reprezentace obrazu.

Nejpřirozenějším způsobem je zahájit narůstání v původních obrazových datech, kde každý pixel představuje samostatnou oblast. Tyto existující oblasti jsou postupně spojovány tak dlouho, dokud by jejich dalším spojením nebyla porušena homogenita.

Štěpení oblastí je principiálně opačný přístup k segmentaci než jejich spojování. Tyto algoritmy vycházejí z počátečního rozdělení obrazu do jediné oblasti. Tento postup je teoreticky duální k postupům spojování oblastí, ale přesto nedává ani při použití stejných kritérií homogenity tytéž výsledky při aplikaci na reálná data.

5.4.4 Segmentace srovnáváním se vzorem

Dalším přístupem k segmentaci je vyhledávání známých objektů v obraze pomocí srovnávání se vzorem (*matching*). Obecně jde o nalezení míst v obraze, kde se vyskytuje daný vzor, který má charakter obrazu.

Kromě hledání objektů a oblastí lze srovnávací metody použít i pro stereoskopické určování vlastností objektů scény, máme-li dva obrazy stejné scény snímané z různých míst. Srovnávat lze na úrovni velmi malých vzorů až po vzory pokrývající celé hledané objekty.

Touto metodou jsou v obraze nalezena všechna místa, kde se nacházejí velmi přesné kopie vzoru. Abychom mohli využít srovnávacích technik i pro hledání vzorů různě natočených nebo zvětšených, bylo by nutné vytvořit pro každou možnou velikost a orientaci samostatný vzor. Jiná možnost je použít sice jediný vzor, ale srovnávat obraz se všemi jeho dovolenými transformacemi.

5.5 Matematická morfologie

Matematická morfologie svým matematickým aparátem vycházejícím z algebry nelineárních operací do značné míry při zpracování signálů či obrazů předstihuje tradiční lineární přístup, který využívá lineární kombinace (konvoluci) bodových zdrojů představovaných Diracovými impulsy [28]. Jde např. o předzpracování obrazu, o segmentaci s důrazem na tvar hledaných objektů, o kvantitativní popis nalezených objektů. Operátory matematické morfologie se obvykle používají tam, kde je požadavek na krátký čas zpracování. Aplikačními oblastmi jsou biologie, geologie, kriminalistika, obrazová inspekce v průmyslu, rozpoznávání znaků a dokumentů, aj. Morfologické metody lze použít jak pro 2D obrazy, tak je možné je využít i pro zpracování 1D signálů.

5.5.1 Základní morfologické pojmy

Matematická morfologie využívá vlastností bodových množin, výsledky z integrální geometrie a topologie. Základním předpokladem je představa, že reálné obrázky lze modelovat pomocí bodových množin libovolné dimenze (např. N -rozměrný euklidovský prostor).

Morfologická transformace je dána relací mezi obrazem a jinou, typicky menší množinou, které se říká strukturní element. Strukturní element je vztažen k „lokálnímu“ počátku, který se nazývá reprezentativní bod.

Aplikaci morfologické transformace si lze představit jako systematické posouvání strukturního elementu po obraze. Výsledek relace mezi obrazem a strukturním elementem se zapíše do výstupního obrazu v reprezentativním pixelu.

Ke každé morfologické operaci existuje duální transformace, což vyplývá z množinových doplňků.

Základními transformacemi matematické morfologie jsou *dilatace*, *eroze*, *otevření* a *uzavření*.

5.5.2 Binární matematická morfologie

5.5.2.1 Dilatace

Dilatace \oplus skládá body dvou množin pomocí vektorového součtu. Dilatace $M \oplus E$ je bodovou množinou všech možných součtů pro dvojice pixelů, vždy pro jeden z množiny A a jeden z množiny B

$$M \oplus E = \{p \in \mathcal{E}^2 : p = m + e, m \in M, e \in E\}. \quad (31)$$

Dilatace je operací komutativní, asociativní a je invariantní vůči posunu. Používá se samostatně k zaplnění malých děr, úzkých zálivů a jako stavební kámen složitějších operací. Dilatace zvětšuje objekty. Často je kombinována s morfologickou operací eroze pro zachování původního rozměru objektů.

5.5.2.2 Eroze

Eroze \ominus skládá dvě množiny podle předpisu

$$M \ominus E = \{p \in \mathcal{E}^2 : p + m \in M \text{ pro každé } e \in E\}. \quad (32)$$

Tento vztah říká, že pro každý bod obrazu p se ověřuje, zda pro všechna možná $p + m$ leží výsledek v M . Pokud ano, zapíše se v reprezentativním bodě do výsledného obrázku 1 a v opačném případě 0.

Eroze není na rozdíl od dilatace komutativní a používá se pro zjednodušení struktury objektů. Eroze ani dilatace nejsou invertovatelné. Mezi těmito operacemi platí vztah duality a tyto transformace označujeme jako duální, což charakterizuje vztah

$$(M \ominus E)^C = M^C \oplus E. \quad (33)$$

5.5.2.3 Otevření a uzavření

Morfologické operace otevření a uzavření jsou tvořeny kombinacemi duálních operací, kterými jsou dilatace a eroze. Výsledkem otevření i uzavření je obraz obsahující méně detailů, dá se tedy považovat za zjednodušený.

Eroze následovaná dilatací vytváří transformaci otevření. Otevření množiny M strukturním elementem E se označuje $M \circ E$ a je definováno jako

$$M \circ E = (M \ominus E) \oplus E. \quad (34)$$

Transformace uzavření je tvořena sledem transformací dilatace a eroze. Oproti otevření je tedy pouze přehozeno pořadí dilatace a eroze. Uzavření množiny M strukturním elementem E se označuje $M \bullet E$ a jeho definice je

$$M \bullet E = (M \oplus E) \ominus E. \quad (35)$$

Pokud se obraz po otevření strukturním elementem nezmění, říkáme, že je vzhledem k němu *otevřený*. Analogicky se definuje *uzavřenost* u transformace uzavření a můžeme říct, že obraz je uzavřený vzhledem ke strukturnímu elementu, pokud nedojde k jeho změně po aplikaci transformace uzavření daným strukturním elementem.

Otevření a uzavření se používá pro odstranění detailů v obraze, které jsou menší než strukturní element. K tomu se používá strukturního elementu, který nezávisí na směru a označuje se tedy izotropický. Celkový tvar objektu potom není porušen. Otevření oddělí objekty spojené úzkou šíjí, a tak zjednoduší strukturu objektů. Transformace uzavření spojí objekty, které jsou blízko u sebe, zaplní malé díry a vyhladí obrys tím, že zaplní úzké zálivy. Blízkost objektů, velikost děr a úzkost zálivů se chápe relativně vzhledem k velikosti strukturního elementu.

Otevření a uzavření jsou duálními transformacemi stejně jako dilatace a eroze

$$(M \bullet E)^C = M^C \circ E. \quad (36)$$


Další důležitou vlastností otevření a uzavření je idempotentnost. To znamená, že opakované použití obou operací již nemění výsledek. Má tedy smysl mluvit o otevřené či uzavřené množině vzhledem ke strukturnímu elementu. Platí tedy následující vztahy

$$M \circ E = (M \circ E) \circ E, \quad (37)$$


$$M \bullet E = (M \bullet E) \bullet E. \quad (38)$$

5.5.3 Skelet

Původní název pro skelet byla „střední osa“ (angl. medial axis transform). Jedná se o morfologickou operaci, která odstraňuje pixely na hranicích objektů za předpokladu zachování jejich souvislosti. Skelet lze laicky vysvětlit na představě o požáru. Pokud na hranici nějakého rovinného plošného útvaru v jednom okamžiku zapálíme oheň, pak je skelet tvořen všemi body, ve kterých se setkají dva a více ohňů. Toto platí za předpokladu šíření ohně všemi směry stejnou a konstantní rychlostí. Například skeletem kruhu je jeho střed, skeletem čtverce jsou jeho úhlopříčky.



Obrázek 5: (a) Čtverec. (b) Skelet čtverce. (c) Obdélník. (d) Skelet obdélníku.
(obrázky jsou invertované kvůli tisku)



Obrázek 6: (a) Kruh. (b) Skelet získaný programem (neodpovídá teorii). (c) Skelet kruhu (jediný bod - střed) odpovídající teorii.
(obrázky jsou invertované kvůli tisku)

5.6 Popis nalezených objektů

Cílem popisu nalezených objektů je buď číselný vektor příznaků nebo nečíselný syntaktický popis charakterizující tvarové nebo jiné vlastnosti popisované oblasti.

K popisu oblastí je důležité definovat jejich tvar. Jedním z hledisek, podle kterých lze rozdělit postupy tvarového popisu, může být charakter vstupní reprezentace - jestli popis vychází ze znalosti oblasti nebo jen z její hranice. Jiným hlediskem je množství zachované informace, jestli lze objekt z popisu znovu rekonstruovat. Další možností je rozdělit metody na matematické a heuristické. Důležité je také to, jestli navržený způsob reprezentace vede k příznakovému nebo syntaktickému popisu.

Nutným předpokladem k popisu oblastí je jejich identifikace, která umožňuje jednoznačně se odvolávat na každou oblast obrazu. Jedním z možných způsobů je přidělit každé oblasti (resp. každé hranici oblasti) jedinečné přirozené číslo. Taková identifikace se nazývá *barvení*.

5.7 Porozumění obsahu obrazu

K celkovému porozumění je třeba pracovat s vnitřním modelem, reprezentujícím "představy" systému počítačového vidění o zpracovávané části reálného světa. Na základě apriorních znalostí zpracovávané scény dochází k vytváření vnitřních modelů, k jejich ověřování a průběžné aktualizaci. K tomu je vždy nutné vykonat vhodnou posloupnost kroků zpracování.

V reprezentaci prostředí jsou nové údaje porovnávány se stávajícím modelem a mohou být použity k modifikaci modelu. Interpretace údajů přitom není jednoznačně závislá jen na údajích samotných. V případě různých výchozích modelů nebo různé předchozí zkušenosti mohou být data interpretována pokaždé odlišným způsobem.

5.7.1 Sémantické metody segmentace a interpretace obrazu

Sémantická informace je znalostí "vyšší" úrovně. Např. při spojování oblastí při segmentaci je logické spojit ty sousední oblasti, které mají stejnou interpretaci. Sémantická informace je v procesu spojování oblastí používána až v pozdějších krocích - když na základě obecných heuristik není další spojování možné, jsou určovány sémantické vlastnosti dosud vytvořených oblastí a je buď povoleno, nebo zakázáno další spojování sousedních oblastí.

Pro praktické využití je třeba navrhnout odpovídající model vzájemných vztahů jednotlivých interpretací oblastí, metody určování věrohodnosti interpretace atd.

5.8 Přístup k vyhodnocení

Při návrhu jakéhokoliv systému, případně softwaru počítačového vidění, je důležité zvolit správný přístup řešení. U průmyslových aplikací je prvním úkolem navrhnout snímací soustavu. Nevhodná volba nebo umístění snímacího zařízení nebo osvětlovače komplikuje nebo znemožňuje vývoj funkčního systému.

Dalším důležitým kritériem jsou požadavky. V případě této práce to je možnost parametrizace algoritmů, jejich případná pozdější modifikovatelnost, uživatelská přívětivost obslužné aplikace nebo případné navázání na další vyhodnocení.

V případě průmyslových aplikací se většinou používají softwarové nástroje s funkcemi analýzy obrazu optimalizovanými na výpočetní výkon. Tyto funkce většinou poskytují výsledky po přímém vykonání na sejmutém obraze. Naproti tomu složitější systémy obsahují algoritmy složené z řetězce funkcí, které zahrnují většinou řadu parametrů.

Filozofií této práce je navrhnout víceúčelové algoritmy využitelné pro zpracování obrazů více typů textilních řezů, případně aplikovatelné na analogické úlohy analýzy obrazu. Základními přístupy předzpracování jako je prahování nebo použití hranového operátoru je získán binární obraz. Tím je sice zredukováno množství obrazových dat, při vhodném použití a nastavení je však informace zachována. Pro některé funkce je vstup v podobě binárního obrazu nutností nebo je mnohem vhodnější než původní obraz.

V binárním obraze potom přicházejí na řadu hlavní úkoly. Nejdříve je potřeba vyfiltrovat objekty, které se nebudou používat pro další zpracování. Těmi mohou být hrany nepředstavující hranici vlákna, malé segmenty neumožňující další zpracování, prostě objekty nesplňující vstupní podmínky. V případě příčných řezů máme k dispozici předpoklad tvaru a velikosti vláken. Tyto parametry můžeme použít jako vstup pro filtr, který nevyhovující objekty odstraní.

Co se týče velikosti, lze využít „bounding box“, respektive jeho výšku a šířku. Další možností je maximální průměr, což je vzdálenost horního levého a dolního pravého bodu objektu. Pro filtrování objektů na základě tvaru průřezu vláken je nejlepší využít řetězového kódu. To je prostředek pro získání stručnější reprezentace množiny pixelů. Popisu řetězového kódu a možnostem jeho použití je věnována kapitola 5.10.

Další fází zpracování je doplnění neuzavřených hranic vláken. Příčiny nekompletnosti objektů byly popsány výše. Pomocí tohoto postupu jsou spojovány koncové body neuzavřených hranic a je vytvářena uzavřená hranice. Podrobnější popis obsahuje samostatná kapitola 5.11.

Posledním krokem je kontrola jednotlivých řezů vláken. V případě nesprávného uzavření hranice je možné chybný objekt představující vlákno odstranit. Pro případ kontaktu jednotlivých vláken lze použít algoritmy separace, které jsou popsány v kapitole 5.12.

5.9 Houghova transformace

Houghova transformace je metoda sloužící k hledání definovaných objektů v obrázku [31]. Protože vyžaduje, aby hledaný objekt byl parametricky popsán, klasická Houghova transformace slouží především k detekci pravidelných křivek, jako jsou úsečky, kružnice, elipsy atd. Zobecněná Houghova transformace může být použita tam, kde není možný jednoduchý analytický popis objektu.

Houghova transformace má mnoho praktických aplikací, například v lékařství. V těchto aplikacích je transformace realizována především k hledání hranic objektů v podobě již zmíněných křivek a úseček.


Hlavní výhodou Houghovy transformace je určitá tolerance rozdílů rozpoznávaných objektů oproti jejich parametrickému popisu a relativní odolnost proti zašumění vstupního obrázku.

Asi nejjednodušší případ je hledání úseček, respektive přímek. Klasická rovnice přímky

$$y = k \cdot x + q \quad (39)$$

nelze použít kvůli neomezenosti parametru k definujícího sklon, tedy směrnici přímky. Jako parametrický popis se proto použije polární tvar rovnice přímky

$$x \cdot \cos \theta + y \cdot \sin \theta = r, \quad (40)$$




Obrázek 7: Parametricky popsaná úsečka.

Jak je zřejmé z obrázku 7, parametr r představuje vzdálenost přímky od počátku (v digitálním obrázku jsou rozměrem pixely) a úhel θ svírají osa x a kolmice vztyčená k přímce procházející počátkem. Intervaly těchto dvou parametrů jsou omezené pro celou množinu všech přímek. Volba těchto dvou intervalů je možná dvěma způsoby, které jsou patrné z obrázku 10. První možností je interval $\langle 0; 360 \rangle$ pro úhel θ , parametr r poté nabývá pouze kladných hodnot, teoreticky až do velikosti úhlopříčky obrázku, kterou lze jednoduše spočítat Pythagorovou větou. Druhou variantou je možnost uvažovat i zápornou hodnotu parametru r , konkrétně tedy dvojnásobný interval oproti první možnosti, čímž je interval úhlu θ zredukován analogicky na polovinu, tedy $\langle 0; 180 \rangle$. Intervaly jsme v počítačové realizaci zredukovali na celá čísla a ještě o jedničku posunuli, aby bylo možné dosáhnout nulových hodnot parametrů.


Před aplikací transformace se nejprve nadefinuje prostor obsahující všechny možné hodnoty parametrů hledaného objektu, který se nazývá akumulátor. Tento prostor je reprezentován n -dimenzionální maticí, kde n je určeno počtem parametrů objektu. V případě úsečky jsou to samozřejmě parametry r a θ , které budou představovat souřadnice akumulátoru. Na počátku musí být všechny hodnoty akumulátoru shodné, obvykle se volí nula.

Transformace funguje tak, že se prochází systematicky obrázek pixel po pixelu. Pokud se narazí na pixel objektu (v našem nejjednodušším případě je vstupem binární obrázek tudíž pozadí...0, objekt...1), dosazuje se do rovnice (40). Proměnné x a y jsou souřadnice nalezeného pixelu. Protože v rovnici jsou dvě neznámé r a θ , za jednu z nich se postupně dosazují všechny hodnoty jejího intervalu vycházející z akumulátoru a druhá hodnota se vypočítá. Pro dvojici takto získaných hodnot $[r, \theta]$ se přičte konstanta, nejčastěji jednička, na příslušné místo do akumulátoru. Hodnoty se tedy akumulují, proto je matice parametrů nazvaná akumulátor.

Po projití celého obrázku se z akumulátoru vyberou lokální maxima, která definují jednotlivé objekty. Z toho vyplývá, že v případě obrázků s různými velikostmi objektů, tedy úsečky různých délek nebo kružnice s různými poloměry, jsou zjednodušeně řečeno detekovány vždy ty objekty, které jsou tvořeny nejvíce pixely, protože jim odpovídá větší maximum v akumulátoru.



Obrázek 8: Binární obrázek vstupující do Houghovy transformace. Obrázek je invertován.



Obrázek 9: Akumulátor odpovídající obrázku 8 jako vstupu Houghovy transformace.

K hledání kružnic se použije opět analytický popis, tedy rovnice kružnice ve tvaru

$$(x - a)^2 + (y - b)^2 = r^2. \quad (41)$$

Počet neznámých ve srovnání s přímkou vzrostl o jedna na hodnotu tři. Tudíž i výpočetní náročnost se zvýšila obecně o jeden řád. Akumulátor je tedy třírozměrný. Parametry jsou střed kružnice o souřadnicích $[a, b]$ a poloměr r . Intervaly hodnot parametrů se dají zvolit podle požadavků a nastavení není jednoznačné. Lze umožnit i detekci kružnic, které nebudou v obrázku zakresleny celé, což vyplývá z principu transformace.

Principiálně je výpočet opět stejný, prochází se tedy systematicky obrázek, příslušné hodnoty jsou dosazovány do rovnice (41) a dochází k akumulaci hodnot v akumulátoru.


5.10 Řetězový kód

Řetězový kód je prostředek pro získání jednorozměrného signálu z digitálního obrazu, tedy signálu dvojrozměrného [29]. Je to stručnější způsob reprezentace množiny pixelů. Může být definován s ohledem na pixely nebo na hranice mezi nimi. Jeho výhodou je jednodušší popis objektů díky reprezentaci řetězového kódu funkcí jedné proměnné. Díky tomu lze například získat příznaky objektů s mnohem menšími výpočetními nároky. Další možností použití je posuzování tvaru hranic vyšetřováním průběhu dalších modifikací základního řetězového kódu.

Aplikovat lze řetězový kód obecně na libovolném rastru (mřížce). Nejčastější varianty jsou pro čtyř a osmiokolí. Čtvercový rastr ale i přes majoritní použití není nejvhodnější volbou. U osmiokolí nastává problém nestejně vzdálenosti (neekvidistantnosti) pixelů sousedících ve vertikálním, respektive horizontálním směru, oproti pixelům ve směru diagonálním. V případě čtyřokolí se sice s problémem neekvidistantnosti nesetkáme, na druhou stranu je ale okolí omezeno pouze na čtyři směry. Pro odstranění nevýhody čtvercové mřížky lze použít mřížku hexagonální, která vypadá jako včelí plástve. Bohužel ani použití tohoto rastru není vhodné ze dvou důvodů. Většina digitalizačních zařízení preferuje mřížku čtvercovou, což je důvod první. Tento rastr také není vhodný pro některé operace jako třeba Fourierovu frekvenční filtraci.


V případě příčných řezů vláken je řetězový kód jednotlivých objektů vytvářen z předzpracovaného binárního obrázku. Objekty představují hranice vláken. Jedná se tedy o hranový obrázek. Kód je potom vytvářen systematickým procházením hranic v osmiokolí

pixel po pixelu. Na základě vzájemné polohy procházených pixelů je vytvářen řetězový kód jako číselná řada z intervalu $\langle 0; 7 \rangle$. Na obrázku 10 jsou číselně označeny všechny směry osmiokolí.



Obrázek 10: Absolutní řetězový kód pro osmiokolí.


Toto je základní typ řetězového kódu známý jako absolutní. Protože obsahuje informaci natočení objektů, která je pro nás neužitečná, je potřeba ho přepočítat do dalšího typu. Tím je relativní řetězový kód. Z absolutního kódu kód relativní získáme jako jeho diskretní derivaci, tedy diferenci. Získáme tedy také posloupnost čísel, nyní ale v intervalu $\langle -3; 3 \rangle$, kdy každá hodnota udává změnu směru průchodu hranových pixelů (edgelů) jako násobek 45° . Z obrázku 11 je patrné označení směrů.



Obrázek 11: Relativní řetězový kód pro osmiokolí.

Hodnoty kladné získáme, pokud procházíme ve směru hodinových ručiček. Jednotlivé směry jak kódu absolutního tak relativního lze označit libovolně jinak při zachování myšlenky metody. Dalším typem je řetězový kód kumulovaný. Ten se získá z kódu relativního postupným sčítáním (kumulací). Tento kód v případě uzavřených hraničních objektů začíná hodnotou o sedm menší než je hodnota konečná pokud ho procházíme ve směru hodinových ručiček nebo hodnotou o sedm větší v případě průchodu opačného. Výhodou tohoto kódu je vhodnost pro zpětnou interpretaci změny tvaru hranice.

Obrázek 12 je názorným příkladem řetězového kódu. Šipky znázorňují přechody mezi sousedícími edgely, a jsou označeny příslušným směrem absolutního, respektive relativního řetězového kódu. V tabulce 2 je potom výpis jednotlivých typů kódů.




Obrázek 12: Způsob tvorby řetězového kódu. (a) Absolutní řetězový kód. (b) Relativní řetězový kód.

absolutní kód	2	2	3	2	2	3	3	4	3	4	4	5	6	6	7	6	5	4	3	4	5	6	6	7	7	0	0	1	0	1	0	0	7	0	1
relativní kód	-	0	1	-1	0	1	0	1	-1	1	0	1	1	0	1	-1	-1	-1	-1	1	1	1	0	1	0	1	0	1	-1	1	-1	0	-1	1	1

Tabulka 2: Řetězové kódy odpovídající obrázku 12.


5.10.1 Úprava hraničních objektů

Při aplikaci řetězového kódu nelze jednoduše procházet hrany bod po bodu pomocí osmiokolí. Setkáváme se s případy ilustrovanými obrázkem 13. Dochází k tomu, že některé vnitřní body hraničních objektů obsahují v osmiokolí více než právě dva sousední edgely, kterými je předchůdce a následník.



Obrázek 13: Nejednoznačnost při aplikaci řetězového kódu.

Nabízí se několik možných řešení. Prvním z nich je v případě dvou následníků použít oba dva, určit jejich pořadí a podle něj vytvořit řetězový kód. Druhou možností je následující pixely zprůměrovat do jednoho. Poslední možností je před výpočtem kódu hranice upravit transformací tref či miň, jak je popsáno dále. Všechny případy jsou ilustrovány v obrázku 14. V porovnání se jako nejlepší jeví poslední způsob, protože prvním dostaneme delší řetězový kód a druhým neceločíselnou hodnotu řetězového kódu. Z hlediska výpočetní náročnosti je nejlepší také poslední možnost. Při vyšetřování tvaru jsou ale všechny metody ekvivalentní z hlediska průměrných hodnot relativního řetězového kódu na dostatečně velkém okolí.



Obrázek 14: Možnosti realizace řetězového kódu.

K dosažení požadavku třetího použitého způsobu je použita morfologická operace ztenčování, která je založena na transformaci tref či miň. Ta hledá shodu strukturních elementů s částí obrazu. Strukturní element B slouží jako vzor pro vyhledávání a s jeho pomocí se dají například vyhledávat rohy, hranice objektů nebo ho lze použít jako v našem případě pro ztenčování. Na rozdíl od ostatních morfologických operací tato operace využívá strukturní elementy dva. Prvním testuje, zda pixely do vstupní množiny X patří, druhým zda nepatří. Tato transformace označená symbolem \otimes je definována jako

$$X \otimes B = \{x : B_1 \subset X \wedge B_2 \subset X^c\}. \quad (42)$$

Strukturní elementy B1 a B2 jsou disjunktní množiny a jejich zápis se dá tedy sdružit do jedné matice při zavedení neurčité hodnoty *, která na rozdíl od hodnoty jedna znázorňuje pixel objektu, a hodnoty nula znamenající pixel pozadí, nemá žádnou hodnotu, a tudíž se testování vůbec nezúčastňuje.

Operace ztenčování je potom definována jako

$$X \oslash B = X \setminus (X \otimes B). \quad (43)$$

Při ztenčování se tedy část objektu detekovaná strukturními elementy odečítá od daného objektu. V našem případě musí být operace ztenčování použita opakovaně (sekvenčně) se všemi osmi strukturními elementy vytvořenými otáčením elementu o 45° . Existuje několik prakticky použitých posloupností strukturních elementů, při jejichž použití nedojde při ztenčování k porušení souvislosti objektu. V obrázku 15 je znázorněn element *L* Golayovy abecedy. Ztenčování se provádí iteračně, dokud se výsledný obraz mění.


0	0	0
*	1	*
1	1	1

*	0	0
1	1	0
*	1	*

Obrázek 15: Strukturní elementy L Golayovy abecedy.

Další možností je použít operaci skeletu ke ztenčení a určení kostry objektu, a poté pomocí elementů Golayovy abecedy a ztenčování odstranit nejednoznačnosti pro aplikaci řetězového kódu.

Obrázek 16 ilustruje aplikaci popsané úpravy. Vlevo je zobrazen detail segmentu před získáním použitím skeletu. Vpravo je již segment po aplikaci úpravy, která umožní následné použití řetězového kódu.



Obrázek 16: Problém nejednoznačnosti při tvorbě řetězového kódu. (a) Detail segmentu, na nějž nelze aplikovat zvolenou realizaci. (b) Upravený segment pro aplikaci řetězového kódu.

5.10.2 Použití

Řetězový kód lze použít na několik základních úloh. První úlohou je filtrace objektů na základě vstupních parametrů. Průřezy vláken splňují určité fyzikální vlastnosti. Průběh hranic nemůže být libovolnou křivkou a je do určité míry omezen. Informaci o lokální změně směru poskytují jednotlivé hodnoty relativního řetězového kódu. Jeho součet, respektive průměr v zadaném okolí, znamená celkové, respektive průměrné zakřivení v zadaném okolí. Tímto postupem je tedy možné odstranit nevláknenné objekty.

Lze ho ale použít i v případě, kdy se v objektu vyskytují neodstraněné nejednoznačnosti. Tím může být například dotyk sousedících vláken nebo malé roztřepené konce vzniklé použitím skeletu. Úlohou separace se zabývá kapitola 5.12.

Další úlohou použití je využití při uzavírání nekompletních řezů vláken, kdy je potřeba párovat místa přerušení a vytvářet mezi nimi spojnice. Popisu tohoto použití je věnována kapitola 5.11.

Poslední úlohou využívající řetězový kód je rozpoznání typu vlákna ve směsných přízích. K tomu je na kumulovaný řetězový kód aplikována Fourierova transformace. Získané spektrum se logaritmicky rozdělí na předem definovaný počet pásem, jejichž velikost je určena v závislosti na jeho celkové délce. Důvodem tohoto rozdělení je lepší rozlišení pro nižší frekvence. Hodnoty v jednotlivých pásmech se posčítají a jsou získány spektrální příznaky. Vlastní rozpoznávání typu vláken poté probíhá metodou maximální pravděpodobnosti. Nejdříve je potřeba uživatelsky vytvořit trénovací množinu. Poté jsou prvky testovací množiny hodnotou výsledné pravděpodobnosti zařazovány do jednotlivých množin.

5.10.3 Spektrální příznaky

Pomocí řetězového kódu tedy lze získat popis nezávislý na natočení obrázku, je však závislý na počátku určování řetězového kódu. Aby bylo možné ho použít, museli bychom zaručit, aby řetězový kód začínal vždy ze stejného bodu. Tento problém lze snadno vyřešit pomocí Fourierovy transformace. Konkrétně jsme použili rychlou diskrétní Fourierovu transformaci (FFT). Tato transformace předpokládá, že vstupující signál je periodický. Nezáleží tedy na umístění počátku. Aplikací transformace na řetězový kód získáme spektrum, které obsahuje spektrální příznaky. Abychom u spektra předešli vysoké hodnotě na první spektrální čáře, tedy stejnosměrné složce, byla od kumulovaného kódu odečtena lineární funkce, která


prochází počátkem souřadného systému $[0, 0]$ a bodem se souřadnicemi $[x_n, 7]$, kde x_n představuje poslední x -ovou souřadnici.

V důsledku použití osmiokolí je do řetězového kódu zanesena určitá nepřesnost, která vyplývá z neekvidistantnosti jednotlivých sousedních bodů. V případě absolutního řetězového kódu to nevadí, protože ten je závislý na natočení. V našem případě je ale modifikace řetězového kódu již na natočení nezávislá. To by mohlo vést k určité deformaci získaného spektra. Tuto nepřesnost by bylo možné odstranit tak, že kromě řetězového kódu by byla vytvářena i posloupnost, která by vyjadřovala vzdálenosti mezi jednotlivými sousedními hranovými pixely (edgely). V případě označení vzdálenosti horizontálně nebo vertikálně sousedících pixelů hodnotou jedna by pro diagonálně sousedící pixely vzdálenost odpovídala logicky odmocnině ze dvou. My jsme neekvidistantnost osmiokolí zanedbali a uvažovali ekvidistantní dělení.


Ze zmíněného spektra získaného z upraveného kumulovaného kódu již určíme příznaky charakterizující jednotlivé objekty a to tak, že spektrum vhodně rozdělíme na několik pásem. Vzhledem k rozdílným délkám spekter jednotlivých objektů je potřeba každé spektrum rozdělit tak, abychom získali vždy stejný počet příznaků sečtením hodnot v jednotlivých pásmech. K tomuto účelu jsme spektra dělili logaritmicky a šířku jednotlivých pásem počítali vzhledem k délce konkrétního spektra. Logaritmické dělení zaručí lepší rozlišení pro nízké frekvence, což je pro náš případ výhodné.

Pro shrnutí bychom tedy uvedli, že ze vstupních informací reprezentovaných binárními obrázky obsahujícími objekty zastoupené jejich hranicemi, jsme výše zmíněným postupem získali příznaky, které jsou použity pro trénování nebo rozpoznávání a následné rozřazování objektů do tříd, které je popsáno v kapitole 5.13.


Na obrázcích 17 - 20 je uveden příklad získání spektrálních příznaků pro uzavřenou hranici popisující řez vláknem.




Obrázek 17: Uzavřená hranice použitá pro výpočet spektrálních příznaků. Obrázek je invertován kvůli tisku.



Obrázek 18: Kumulovaný řetězový kód získaný z uzavřené hranice na obrázku 17.



Obrázek 19: Upravený kumulovaný kód vypočítaný z kumulovaného kódu na obrázku 18.



Obrázek 20: Spektrum vytvořené z upraveného kumulovaného kódu na obrázku 19.

5.10.3.1 Další příznaky


Kromě příznaků spektrálních, které se získávají pomocí aplikace řetězového kódu a Fourierovy transformace, lze jako příznak použít kteroukoli charakterizující vlastnost jako je například plocha, obvod, rozměry atd. Důležité je vždy umět zvolit co nejvhodnější příznaky. V případě plochy, obvodu nebo rozměrů je důležité neopomenout to, že tyto příznaky jsou závislé na rozlišení a jsou vhodné především tam, kde je velikost objektu klíčová. Zajímavým příznakem je nekompaktnost. Tento příznak se spočte z hodnot obvodu, respektive délky hranice objektu, a jeho plochy pomocí vzorce

$$\text{nekompaktnost} = \frac{(\text{délka_hranice})^2}{\text{plocha}}. \quad (44)$$

Tento příznak lze použít v případech, kde velikost objektů jednoho typu není vždy stejná. Je důležité ale vědět, že se zvětšujícím se rozlišením obrázku bude hodnota tohoto příznaku narůstat nade všechny meze, což vyplývá z faktu, že délka hranice při zvětšování rozlišení roste na rozdíl od plochy, která konverguje k určité hodnotě.

5.11 Doplnování neuzavřených hranic vláken

Nejjednodušším způsobem opravy nekompletní hranice je její uzavření spojením koncových bodů úsečkami, jak je ukázáno v obrázku 21. Toto lze použít pouze v případě, že průřez vlákna obsahuje pouze jedno přerušení, které je krátké. V případě více přerušení není jednoznačné, které koncové body spojit, protože nenáleží jednomu objektu. Je tedy nejdříve nutné zjistit, které objekty tvoří jedno vlákno. Nejvýhodnější je začít uzavírat největší objekty. Na základě předpokladu maximální velikosti lze omezit oblast zájmu, respektive množinu, ve které se mohou vyskytovat segmenty vlákna. Koncové body těchto segmentů je poté potřeba párovat a segmenty spojit. Pomocí řetězového kódu lze v okolí přerušení usuzovat směr jeho pokračování. Tím lze některé segmenty vyřadit z množiny.



Obrázek 21: (a) Přerušená hranice vlákna se zvýrazněním místa přerušení. (b) Uzavření segmentů úsečkami.

Po získání dvojice koncových bodů je potřeba vytvořit mezi nimi spojnici. Pokud je jejich vzdálenost malá lze použít úsečku. V případě větší vzdálenosti lze opět pro konstrukci použít řetězový kód, a ve většině případů lze začátek spojnice vystavět pomocí řetězového kódu okolí obou bodů. Další možností je při vytváření spojnice uvažovat i jasové hodnoty odpovídajících pixelů vstupního obrázku dané cesty a upřednostňovat ty s menší hodnotou v případě tmavých objektů a světlého pozadí. Průměrná intenzita vytvořené spojnice by potom měla být nižší, než jsou typické hodnoty pozadí. V opačném případě lze usuzovat na neúspěšnost algoritmu. Další kontrolou může být použití spektrálních příznaků pro výpočet pravděpodobnosti příslušnosti do trénovací množiny, jak již bylo popsáno pro analogický případ rozpoznávání typu vlákna. Pro nízké hodnoty pravděpodobnosti lze opět předpokládat, že algoritmus selhal.

5.12 Separace segmentů a vláken

Tato kapitola popisuje řešení problému oddělování vláken od dalších vláken nebo od nevláknenných objektů. V případě konvexních vláken máme k dispozici omezující parametr, který lze využít ve znázorněném případě z obrázku 22, kdy v místech dotyku, respektive křížení, je potřeba rozhodnout, které segmenty patří k sobě. V tomto případě mají všechny nenulové hodnoty relativního řetězového kódu daného segmentu stejné znaménko. V případě průchodu ve směru hodinových ručiček jsou všechny hodnoty nezáporné, při procházení proti směru jsou všechny nekladné (záporné nebo nulové).




Obrázek 22: Dotýkající se vlákna se zvýrazněním míst dotyku.

I v případě nekonvexních průřezů vláken můžeme řetězový kód použít. Fyzikální vlastnosti vláken neumožňují libovolný tvar jako třeba velké lokální změny směru představovány ostrými rohy. Takto lze jednoznačně vyloučit, které segmenty se mohou dotýkat a které ne.


Jako alternativy pro separaci, tentokrát ale úplných hranic vláken, můžeme použít i další postupy. Jedním z nich je separace vláken pomocí transformace rozvodí, druhou metodou je použití váženého skeletu.

5.12.1 Separace pomocí rozvodí

Segmentace využívající transformaci rozvodí (angl. watershed) obsahuje dva hlavní kroky: vzdálenostní funkci a jako druhý krok právě transformaci rozvodí. Vzdálenostní funkce pracuje s binárním obrázkem a jejím výstupem je obrázek šedotónový. Její význam je nahradit všechny pixely objektu hodnotou odpovídající nejkratší vzdálenosti daného pixelu od pozadí. V případě segmentace rozvodím se hodnoty vzdálenostní funkce převedou na hodnoty opačné. Touto úpravou se vlastně lokální maxima změní na lokální minima. Výstup je zobrazen na obrázku 23(b). Obrázek 24 ilustruje 3D pohled na výstup opačné vzdálenostní funkce pro tři dotýkající se objekty.




Obrázek 23: (a) Vstupní obrázek získaný předzpracováním. (b) Vzdálenostní funkce.




Obrázek 24: Ilustrační obrázek opačné vzdálenostní funkce pro tři vlákna.

Na šedotónový obrázek vzniklý aplikací záporné vzdálenostní transformace se již aplikuje transformace rozvodí. Význam rozvodí se dá vysvětlit na jednoduché analogii. Pokud si představíme krajinu za deště, můžeme pozorovat, že voda postupně stéká do nejnižších míst, ve kterých se tvoří kaluže. Tyto oblasti s regionálními minimy se nazývají úmoří. Rozvodí, často nazývané také jako linie rozvodí, oddělují jednotlivá úmoří. Příklad oblastí úmoří a linií rozvodí je na obrázku 25. V našem případě jsou úmoří tvořena řezy jednotlivých vláken a linie rozvodí tyto úmoří oddělují.



Obrázek 25: Znázornění úmoří a rozvodí.

Linie rozvodí získané z obrázku 23(b) jsou zobrazeny na obrázku 26(a). Obrázek 26(b) ukazuje, jak jednotlivé linie rozvodí oddělují vlákna. Posledním krokem je již logický rozdíl vstupního binárního obrázku a obrázku linií rozvodí. Jak úspěšný je algoritmus separace je vidět na obrázku 27. Na obrázek byla použita značkovácí funkce, která každý objekt označí jinou barvou, aby byl výsledek názorný.



Obrázek 26: (a) Linie rozvodí oddělující jednotlivá úmoří. (b) Zobrazení linií rozvodí do vstupního obrázku.

Starší postup pro oddělení objektů využívá konečné eroze a podmíněné dilatace. Konečná eroze nahrazuje vzdálenostní funkci. Její význam je nahradit každý objekt značkou. Každý objekt se tedy eroduje tak dlouho než z obrazu zmizí a zůstane z něho značka. Následně se použije podmíněná dilatace pro růst značek. Dilatace se provádí tak dlouho, dokud jsou plněny dvě podmínky. První z nich je zůstat při dilatování uvnitř jednotlivých objektů a druhá požaduje nespojení jednotlivých dilatovaných oblastí.



Obrázek 27: Označovaná oddělená vlákna.

Nevýhodou segmentace rozvodí je citlivost na tvar hranice objektů, která může obsahovat konkávní části ve tvaru malých zálivů, což vede k rozdělení objektu, jak je ukázáno na obrázku 28. Objekt představující průřez vlákna je segmentací rozdělen na dva objekty.




Obrázek 28: Problém segmentace rozvodí.

Dalším algoritmem segmentace pro oddělení objektů je postup založený na morfologické operaci skeletu. Tento algoritmus je oproti transformaci rozvodí výpočetně méně náročný a odstraňuje problém oddělení objektů z obrázku 28.

5.12.2 Separace založená na použití váženého skeletu

Zmíněný algoritmus využívá skelety jednotlivých objektů. Idea skeletu se dá vysvětlit na představě o požáru trávníku. Tvar trávníku bude odpovídat tvaru objektu, jehož skelet chceme získat. Trávník zapálíme v jednom okamžiku po celém obvodu a předpokládáme, že se oheň šíří všemi směry stejnou a konstantní rychlostí. Body styku dvou a více ohňů potom tvoří skelet objektu. Definice skeletu vychází z termínu *maximální kruh*, který představuje kruh vepsaný do objektu dotýkajícího se alespoň ve dvou bodech hranice objektu. Skelet je potom množina středů všech maximálních kruhů, a proto se také někdy označuje jako střední osa.

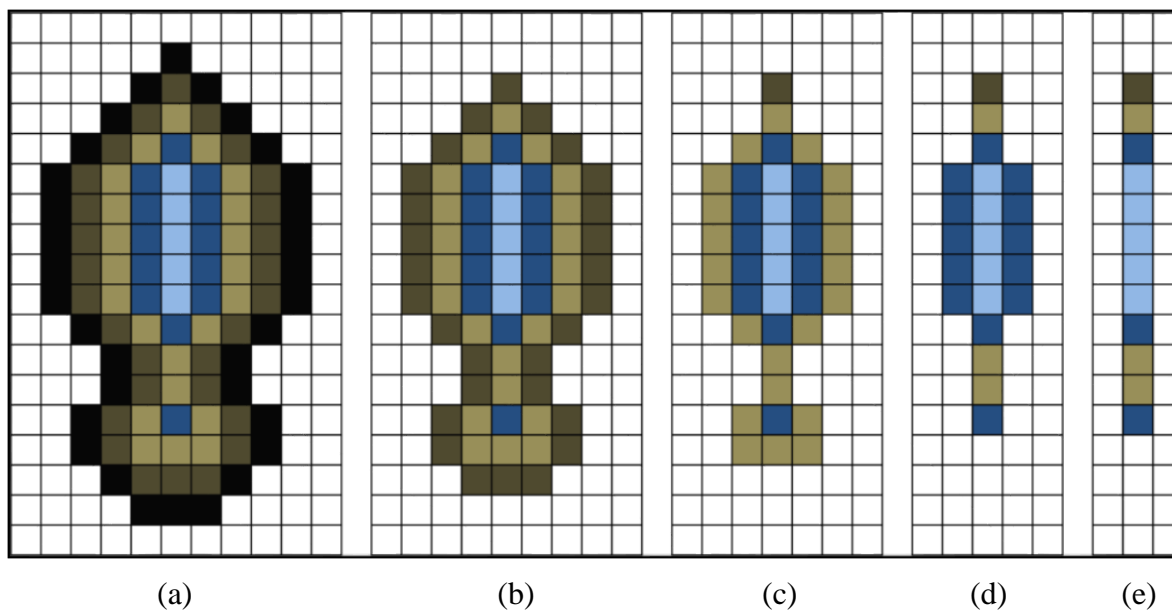
Skelet objektu se dá získat opakovaným užitím eroze. Před provedením eroze jsou všechny pixely hranice objektu testovány, zda nepatří do skeletu objektu. Sousední pixely hraničního pixelu jsou v oblasti o velikosti 3x3 (včetně pixelů skeletu nalezených dříve) testovány, zda tvoří souvislou množinu. Pokud sousední pixely jsou nespojené, tento pixel hrany náleží do skeletu objektu, protože jeho odstranění způsobí rozdělení objektu. Obrázek 29 ukazuje příklady spojených a nespojených oblastí sousedních pixelů. Speciální příklad je oblast obsahující pouze jeden sousední pixel což znamená, že testovaný bod představuje koncový bod skeletu.



Obrázek 29: (a) a (b) Spojené oblasti. (c) a (d) Nespojené oblasti.


● ... pixel hrany, ⊗ ... sousední pixel, □ ... prázdná pozice rastru

Skelet obsahuje pouze informaci o podélném tvaru objektu. Pro segmentaci pomocí skeletu je potřeba mít i informaci o příčném tvaru objektu. Ta je získána jako počet odstraněných vrstev, respektive nejmenší vzdálenost aktuální vrstvy k hraně objektu. Těmito hodnotami jsou potom ohodnoceny jednotlivé pixely skeletu a je tím získán vážený skelet, jehož ukázka je na obrázku 30.



Obrázek 30: Skeletonizace: (a) Vstupní objekt. (b) Po provedení jedné eroze. (c) Po provedení druhé eroze. (c) Po provedení třetí eroze. (e) Vážený skelet.

Po získání váženého skeletu se hledají pixely skeletu, které by mohly představovat spojnice jednotlivých objektů, vyhodnocením skeletu jako funkce. Nezávislou proměnou je délka a závislou proměnou je hodnota skeletu představující minimální vzdálenost od hranice objektu. Vzdálenostní profil je tedy tvořen postupně sousedními hodnotami skeletu. Pro vyhodnocení jsou použity parametry podle obrázku 31. Celková délka je označena L , maximální vzdálenost d_{max} , minimální vzdálenost d_{min} a hloubka poklesu $D = d_{max} - d_{min}$.



Obrázek 31: Vzdálenostní profil skeletu.


Spojnice dotýkajících se objektů se potom hledají jako lokální minima vzdálenostního profilu váženého skeletu.

5.13 Metody rozpoznávání

V této části jsou představeny rozpoznávací metody. O této problematice pojednávají prameny [22], [23] nebo [24].

5.13.1 Principy rozpoznávání a základní pojmy

Řada příznakových rozpoznávacích metod se uplatňuje vedle populárních neuronových sítí pro klasifikaci různých úloh. V rozpoznávacích metodách je první etapou fáze učení, bez níž nelze rozpoznávání realizovat. U systému umělé inteligence zabývajícího se rozpoznáváním lze postup charakterizovat schématem uvedeným v obrázku 32.



Obrázek 32: Obecné schéma rozpoznávače

Úlohou metod rozpoznávání je zařadit *objekt* do některé ze *tříd* podle jeho obrazu. Termín *třída*⁶⁸ představuje skupinu objektů s podobnými vlastnostmi. Postup vlastního rozpoznávání se nazývá *klasifikace*. Obrazem objektu je reprezentativní vyjádření vlastností daného objektu pomocí kvantitativního nebo kvalitativního popisu, který se použije pro rozpoznávání. Postup rozpoznávání se poté realizuje na obraze předmětu, nikoliv tedy na vlastním předmětu, protože ten je často nepochopitelný. Volba obrazu objektu se řídí následujícími podmínkami:

- chyba klasifikace musí být co nejmenší
- obraz objektu je potřeba získat s nejmenším úsilím
- proces vlastního rozpoznávání musí být co nejefektivnější

⁶⁸ vychází z anglického termínu *class*

Procesu rozpoznávání musí předcházet fáze *učení (trénování)*⁶⁹, kdy do systému vstupuje jistý soubor obrazů objektů, u nichž je známá jejich příslušnost do daných tříd. Tento soubor obrazů objektů se nazývá *trénovací množina*. Fáze učení může probíhat sekvenčně s průběžným testováním a zpřesňováním. *Testování*⁷⁰ je fáze, při které se počítá chyba klasifikace na skupině obrazů objektů se známou příslušností ke třídám. Takový soubor se označuje *testovací množina*. V případě úloh, ve kterých se nesetkáme s více identickými objekty, se musí klasifikátor navrhnout dostatečně robustně.

5.13.2 Rozpoznávací systém založený na příznakovém popisu

Pokud je systém založený na příznakovém popisu, obraz objektu je reprezentován příznakovým vektorem

$$x = [x_1, x_2, x_3, \dots, x_n]. \quad (45)$$

Počet složek vektoru příznaků je určen naší volbou. V modelovém příkladu rozpoznávání typu vozidla kdy chceme určit, zda se jedná o osobní či nákladní vozidlo, může být příznakový vektor tvořen jednou složkou představující pohotovostní hmotnost. Další složkou by mohla být maximální konstrukční rychlost. V případě volby obou příznaků daná úloha nebude splňovat podmínky formulované v kapitole 5.13.1. Za podmínky, že je dostačující použití jediného příznaku a přidáním dalšího nezískáme lepší výsledek klasifikace, pak takový příznak přinese prakticky pouze větší výpočetní náročnost.


Vektor příznaků x vstupuje do klasifikátoru, který dává na výstupu definici třídy, jejíž prvkem je objekt popsáný tímto příznakovým vektorem. Matematický zápis obecného klasifikátoru je

$$T = d(x). \quad (46)$$

Schéma klasifikátoru je uvedeno v obrázku 33.


⁶⁹ v angličtině ekvivalentem pojmu *training*

⁷⁰ vychází s anglického pojmu *testing*

Obrázek 33: Systém s N vstupy a jedním výstupem.

5.13.3 Metoda diskriminačních funkcí

Tato metoda je založena na předpokladu, že prostor obrazů objektů je možno rozdělit do disjunktních částí s využitím rozdělovacích *nadploch*. Termín *nadplocha* je obecným termínem pro N -rozměrný prostor. Pokud máme jeden příznak a tedy jednorozměrný prostor, je rozdělovací nadplochou bod. U příznaků dvou a dvourozměrného prostoru je nadplochou křivka. S přidáním dalšího příznaku se již jedná o třírozměrný prostor s rozdělovací nadplochou ve formě plochy. Velkou nevýhodou této metody, v případě složitějších úloh s větším počtem příznaků, je složitý tvar diskriminačních funkcí, které se určují velice obtížně. Metoda diskriminačních funkcí je tedy vhodná pro málo komplikované rozdělení prostoru příznaků. Schéma klasifikátoru s diskriminačními funkcemi je uvedeno na obrázku 34.



Obrázek 34: Schéma klasifikátoru s diskriminačními funkcemi.

5.13.4 Metoda minimální vzdálenosti

Metoda minimální vzdálenosti je metodou, kdy jsou třídy reprezentovány svými představiteli, kteří jsou získáváni ve fázi trénování. Tato metoda se používá ve dvou základních úpravách:


- pravidlo nejbližšího souseda - NN⁷¹
- pravidlo k -nejbližších sousedů - kNN

V prvním případě pravidla nejbližšího souseda je testovaný vzorek zařazen do třídy, od jejíhož představitele je vzdálen nejméně. Druhá možnost pravidlo k -nejbližších sousedů funguje tak, že se testovaný vzorek přiřadí do dané třídy, pokud platí, že představitelé této třídy jsou v nejpočetnějším zastoupení v uspořádané k -tici nejbližších sousedů. Tato metoda rozpoznávání předpokládá značně velkou trénovací množinu pro dosažení dobré úspěšnosti. Fáze trénování je poměrně nenáročná z důvodů pouhého sběru dat. Naproti tomu fáze samotného rozpoznávání je velmi závislá na velikosti trénovací třídy, která určuje míru výpočetní náročnosti. Tuto vlastnost potlačuje úprava, která je popsána dále.

5.13.5 Metoda minimální vzdálenosti s reprezentací etalonem

Tato metoda je upravena za účelem snížení výpočetní náročnosti pro zrychlení algoritmu rozpoznávání. Použitá modifikace odstraňuje závislost velikosti trénovací množiny na výpočetní náročnosti rozpoznávání. Výpočetní náročnost díky úpravě závisí pouze na počtu etalonů. Počet etalonů je logicky totožný s počtem tříd a jejich získání zesložituje fázi trénování a zvyšuje jeho výpočetní náročnost ve srovnání dané metody bez použití etalonu. Klasifikátor dané metody s modifikací je uveden na obrázku 35.

⁷¹ zkratka NN pochází s anglického sousloví *Nearest Neighbours* (nejbližší soused)



Obrázek 35: Schéma klasifikátoru s reprezentací pomocí etalonem.

Nevýhodou zavedení etalonů je neuvažování rozptylu jednotlivých prvků třídy v rozhodovacím procesu. Tento fakt v některých případech může negativně ovlivňovat úspěšnost rozpoznávání. Toto je splněno ale pouze při uvažování Euklidovské vzdálenosti definované jako

$$d(x, y) = \sqrt{\sum_{i=1}^p (x_i - y_i)^2}. \quad (47)$$

Lze však použít tzv. *Mahalanobisovu vzdálenost* definovanou vztahem


$$d_M(x, y) = \sqrt{\frac{\sum_{i=1}^p (x_i - y_i)^2}{\sigma^2}}, \quad (48)$$

která zohledňuje i rozptyl prvků a docílíme tak větší úspěšnosti rozpoznávání. Rozptyl jednotlivých příznaků je dán vztahem

$$\sigma^2 = \frac{1}{K} \sum_{i=1}^K (x_i - \bar{x})^2. \quad (49)$$

5.13.6 Metoda maximální pravděpodobnosti

Metoda maximální pravděpodobnosti se často také označuje jako metoda maximální chyby [26]. Na obrázku 36 je zobrazen klasifikátor s výpočtem maximální pravděpodobnosti.



Obrázek 36: Schéma klasifikátoru s výpočtem maximální pravděpodobnosti.

Pro normální rozdělení pravděpodobnosti lze vyjádřit vztah

$$p(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\bar{x})^2}{2\sigma^2}}. \quad (50)$$

Pro výpočet pravděpodobnosti z vícerozměrných veličin tento vztah vypadá takto

$$p(x) = \frac{1}{\sqrt{(2\pi)^p \det \Sigma}} e^{\left(-\frac{1}{2}(x-\bar{x})^T \Sigma^{-1}(x-\bar{x})\right)}. \quad (51)$$

Ve vztahu (51) vystupuje místo rozptylu ze vztahu (50) *kovarianční matice*, která se značí symbolem Σ a je obecně definována vztahem


$$\Sigma = \begin{bmatrix} \sigma_{11}^2 & \sigma_{12}^2 & \dots & \sigma_{1n}^2 \\ \sigma_{21}^2 & \sigma_{22}^2 & \dots & \sigma_{2n}^2 \\ \dots & \dots & \dots & \dots \\ \sigma_{n1}^2 & \sigma_{n2}^2 & \dots & \sigma_{nn}^2 \end{bmatrix}. \quad (52)$$

Kovarianční matice je zobecněním rozptylu pro vícerozměrné veličiny. Prvky na hlavní diagonále představují rozptyly (druhé centrální momenty) jednotlivých veličin. Prvky ležící mimo hlavní diagonálu znamenají míru intenzity vztahu mezi jednotlivými proměnnými, jedná se tedy o kovariance. Jedná se o druhý smíšený centrální moment. Rozptyly i kovariance vystupující v kovarianční matici lze definovat vztahem

$$\sigma_{ij}^2 = E[(x_i - \bar{x}_i)(x_j - \bar{x}_j)]. \quad (53)$$

Jednou z vlastností kovariance je to, že je symetrickou funkcí svých argumentů. Toto lze odvodit z definičního předpisu druhých centrálních momentů (53). Ze symetričnosti kovariance plyne, že i kovarianční matice bude symetrická. Všechny významné prvky budou v kovarianční matici na hlavní diagonále, pokud nejsou vektory příznaků korelované. Za předpokladu, že jsou

jednotlivé prvky vícerozměrné veličiny nekorelované, lze kovarianční matici získat pouze vložením jednotlivých rozptylů na hlavní diagonálu. Zbývající prvky se položí rovné nule. Jak může pravděpodobnostní rozložení vypadat pro vektor příznaků se dvěma složkami je znázorněno na obrázku 37.



Obrázek 37: Podmíněná hustota pravděpodobnosti pro vektory příznaků se dvěma složkami.

5.13.7 Výběr a volba příznaků

Z obecně platných informací vycházejících z praktických zkušeností vyplývá, že kvalita příznaků velkou měrou závisí na úspěšnosti rozpoznávání. V některých případech větší množství příznaků přináší větší úspěšnost rozpoznávání. Nicméně s nárůstem počtu příznaků je potřeba provést více výpočtů a zvětšuje se tedy čas nutný pro provedení rozpoznávání. Proto je klíčové zvolit příznaky vhodně. Univerzální postup ale bohužel neexistuje. Volba příznaků je tak téměř vždy založena na dostupnosti měřicích metod pro jejich získávání, a také na intuici autora. Také se často volí větší počet příznaků, z kterých se poté případně analyticky vybírají ty nejlepší. Na příznaky jsou kladeny tyto požadavky:

- reprezentativnost – příznaky dobře reprezentují objekty tříd
- praktičnost – použitelnost a dostupnost při klasifikaci
- diskriminativnost – co nejlepší rozlišení mezi třídami
- nekorelovanost – co nejmenší vazba mezi příznaky

Každá metoda redukce počtu příznaků má za úkol vybrat jenom takové příznaky, které jsou podstatné při rozpoznávání. Zároveň je při redukci příznaků snížena výpočetní náročnost celého rozpoznávacího algoritmu.

Za tímto účelem lze využít metod založených na transformaci obrazového prostoru, které vycházejí z *Loève-Karhuenova rozvoje*, kdy se původní příznakové vektory převádějí na vektory s jinou velikostí pomocí vhodné lineární transformace. Hledá se taková transformace, která splní podmínku, že vzdálenost vektorů příznaků bude minimální. Pro určení transformační matice existuje známý postup. Nejprve se sestaví čtvercová matice o rozměru odpovídající počtu příznaků. Může to být kovarianční matice⁷² nebo autokorelační matice. Transformační matice se poté vytvoří z vlastních vektorů matice, které odpovídají vlastním číslům matice seřazeným sestupně. Použije se tolik vektorů, resp. vlastních čísel, jaký je rozměr transformovaných příznakových vektorů.

5.13.8 Učení a klasifikace bez učitele

Jednou možností trénování rozpoznávacích metod je učení „bez učitele“. Při jeho použití není před vlastním rozpoznáváním sada trénovacích dat rozdělena do tříd. Ty jsou navrženy samoučícím algoritmem, který určí i počet tříd, který není také předem znám. Jednou takovou metodou rozpoznávání může být například algoritmus LBG⁷³. Metody učení bez učitele se používají jako příprava pro definici rozpoznávací úlohy.

⁷² vyjádření kovarianční matice je v kapitole 5.13.6

⁷³ název algoritmu LBG je vytvořen z počátečních písmen jmen autorů – Linde, Buzo a Gray

6 Detekce vláken pomocí Houghovy transformace

Houghovu transformaci představenou v kapitole 5.9 je možné použít pro detekci vláken v příčných řezech některých přízí [36]. V této kapitole je ukázáno její použití na příčné řezy textile, jejíž vlákna mají přibližně kruhový průřez. Transformace tedy v obraze vyhledává objekty s kruhovým průřezem, které představují jednotlivá vlákna příze.

Jako vstup je použit binární obrázek, který je získáván vhodným předzpracováním. Důsledkem robustnosti transformace, v podobě tolerance rozdílů objektů a odolnost proti zarušení, je značná výpočetní náročnost algoritmu. Transformaci lze použít i na obrazy s více kvantovacími úrovněmi, v takovém případě je ale algoritmus ještě mnohem více výpočetně náročnější.

Výpočetní časy u dodaných obrázků řezů přízí se pro automaticky nastavenou velikost akumulátoru pohybovaly řádově v minutách, proto bylo nutné modifikacemi algoritmu časy redukovat. První modifikací bylo nahrazeno toto automatické nastavení velikosti akumulátoru, které nastavovalo zbytečně velký interval hodnot poloměru, nastavením uživatelským. Interval poloměru byl automaticky nastavován podle velikosti obrázku a to tak, aby bylo možno detekovat kružnice s maximálním průměrem odpovídajícím menšímu rozměru obrázku. Minimální poloměr omezen nebyl. To je samozřejmě pro tuto aplikaci, tedy rozpoznávání vláken, zbytečné. Touto úpravou se povedlo časy snížit více než desetkrát, jsou ale kladeny nároky na uživatele. Pokud uživatel velikost akumulátoru, respektive interval parametru r nevhodně nastaví, mohou být výstupní data chybná.

Druhou modifikací je nastavení koeficientu náhodnosti, který říká, zda se bude výpočet a akumulace provádět pro každý pixel objektu. Pro implicitní hodnotu jedna je výpočet prováděn pro každý objektový pixel v binárním obraze, pro hodnotu n je výpočet prováděn v průměru pro každý $n/2$ -tý pixel. Je použit generátor náhodných čísel s rovnoměrným rozdělením, který generuje hodnotu od nuly do $n-1$, která říká, kolik pixelů objektů se při výpočtu vynechá.

Další úpravou je možnost použít filtraci akumulátoru. Po dokončení akumulace před hledáním maxim akumulátoru je možno použít průměrovací filtr se symetrickou maskou velikosti tři nebo pět. Masky je trojrozměrná podle počtu dimenzí akumulátoru. V důsledku počtu dimenzí je výpočet algoritmu filtrace časově náročný i přes jeho optimalizaci a celková doba filtrace je samozřejmě závislá na velikosti akumulátoru.

Poslední fází je získání parametrů hledaných objektů reprezentovaných maximy akumulátoru. Pro tento účel bylo použito hledání globálních maxim akumulátoru. Nalezené


maximum je v akumulátoru vynulováno a hledání se opět opakuje. Tento postup končí, pokud se v akumulátoru již nenachází hodnota vyhovující stanovené minimální limitní hranici.

Jako výstup jsou získány výsledky v podobě parametrů kružnic, podle kterých je zkonstruován obrázek pro kontrolu úspěšnosti detekce. Míra korespondence hledaných a nalezených objektů je jednoznačně patrná z obrázku 38, který vznikne vykreslením zkonstruovaného obrázku do obrázku původního, který byl pro hledání objektů použit.




Obrázek 38: Obrázek zobrazující vstupní a výstupní objekty umožňující vizuální kontrolu úspěšnosti detekce.

Po výpočtu algoritmu lze vizualizovat také akumulátor. Protože je v případě kružnic, jak již bylo zmíněno, akumulátor třírozměrný, je pro zobrazení zanedbán parametr poloměru a jsou zobrazeny maximální hodnoty pro všechny dvojice hodnot parametrů $[a, b]$, což se dá jednoduše představit jako promítnutí lokálních maxim do plochy o souřadnicích $[a, b]$. Získané hodnoty jsou převedeny do barevné teplotní škály a vykresleny do obrázku 40. Nejnižší hodnotě akumulátoru podle zvolené barevné stupnice odpovídá modrá, nejvyšší hodnotě, která ukazuje na detekovanou kružnici, odpovídá červená.



Obrázek 39: Binární obrázek vstupující do Houghovy transformace.




Obrázek 40: Grafické znázornění akumulátoru náležícího k obrázku 39. K zobrazení je použito teplotní stupnice.


Tyto výsledky (podobně jako z aplikací v kapitolách 7 a 8) lze použít pro určení parametru *zaplnění* μ [3], který představuje podíl objemu vláken k objemu celého vláknenného útvaru. U příčného řezu to tedy je poměr plochy vláken k celkové ploše řezu. Při určování *zaplnění* příze *metodou Secant* [37] je potřeba, kromě základní segmentace v podobě rozdělení obrazu příčného řezu na plochu vláknennou a nevláknennou, mít informace o jednotlivých objektech reprezentujících vlákna pro určení jejich plochy a těžiště.

7 Separace vláken pomocí váženého skeletu


Použitý postup je založen na vyšetřování váženého skeletu a byl představen v kapitole 5.12.2. Jako podmínky hledání může být stanoveno několik kritérií. Prvním z nich je minimální poměr L/d_{max} . V případě kruhových objektů, můžeme v závislosti na předpokládaném poloměru nastavit koeficient spolehlivě. Pokud je délka L výrazně větší než maximální vzdálenost d_{max} , je silný předpoklad, že skelet spojuje více objektů. V opačném případě skelet nejspíše obsahuje pouze jeden objekt. Dalším kritériem hledání je vyhodnocení hloubky poklesu D . Pokud je hodnota parametru D větší než stanovený práh, v daném místě se spojnice objektů uvažuje. Na obrázku 41 je uveden příklad. Bod skeletu s hodnotou d_{min} představuje místo spoje, jak je znázorněno na obrázku 42. Kolmice ke skeletu vedená bodem spoje potom jednoznačně odděluje jednotlivé objekty. Hodnotu prahu je vhodné nastavit uživatelsky tak, aby se jako místa spojení nevyhodnocovaly malé poklesy, které nepředstavují spojnice, ale pouze zúžení objektů. Na obrázku 43(c) je vidět již výsledek daného postupu.



Obrázek 41: Příčný řez: (a) Vstupní obrázek. (b) Naprahovaný obrázek. (c) Předzpracovaný obrázek určený ke zpracování.



Obrázek 42: Průběh profilu váženého skeletu odpovídajícího skeletu z obrázku 43(b) s vyznačenými body spojů.




Obrázek 43: (a) Získaný vážený skelet zobrazený v teplotní stupnici. (b) Vzdálenostní funkce se zobrazením upraveného skeletu. (c) Označovaný obrázek oddělených vláken.

Spoj dvou objektů může být v některých případech dlouhý. Vzdálenostní profil potom obsahuje pás pixelů s hodnotou d_{min} , jehož délka odpovídá délce spoje. Objekty se potom dají oddělit uprostřed tohoto lokálního minima nebo po jeho obou stranách, čímž vznikne větší mezera.

U průběhu vzdálenostního profilu váženého skeletu může dojít k několika speciálním případům. Jedním z nich je jednostranný pokles. Tato situace nastává většinou u krajních

objektů obrázků, které nejsou v obrázku celé. Takové objekty je vhodné po oddělení smazat, protože nenesou kompletní informaci pro další zpracování. Dalším případem je objekt, který obsahuje úzký konec. Tento případ je podobný jednostrannému poklesu, protože vzdálenostní profil obsahuje lokální minimum ostře ohraničené pouze z jedné strany. Pokud dojde ke spojení více objektů, vzdálenostní profil bude obsahovat více lokálních minim, jejichž počet odpovídá počtu spojů a vyhodnocení je analogické.

V případě spojení více objektů, které na sebe navazují v různých směrech, může dojít k tomu, že se skelety jednotlivých objektů kromě spojení i kříží a vytvářejí síť. Typické případy jsou uvedeny na obrázku 44. V případě konvexních objektů se průsečíky jednotlivých skeletů objeví přibližně ve středu objektů. Síť potom může být rozdělena v těchto bodech, čímž získáme několik samostatných skeletů obsahujících dva konce. Následuje postup vyhodnocení, který byl již popsán. První případ z obrázku 44 ukazuje tři objekty, které se dotýkají vzájemně a vytvářejí trojúhelníkový skelet s krátkými větvemi. Tato síť může být rozložena na tři části v bodech, kde se jednotlivé skelety protínají a to tak, že se snažíme získat přibližně stejně dlouhé úseky. V případě tří nebo více překrývajících se objektů je síť tvořena několika větvemi a obsahuje pouze jeden průsečík. V tomto druhém případě obrázku 44 není splněn minimální poměr celkové délky a maximální vzdálenosti. Oddělení objektů se dá provést pouze tak, že se podle počtu větví odpovídajících počtu objektů hledá stejný počet bodů hranice, které jsou nejbližší průsečíku sítě skeletů a odpovídají spojům dvojic objektů. Oddělující čáry potom spojují tyto jednotlivé body a průsečík. Skelety vzájemně se dotýkajících objektů mohou tvořit uzavřené křivky, jak je vidět na obrázku 44 ve třetím případě. V maximální hodnotě vzdálenostního profilu skeletu se síť může přerušit, čímž získáme opět skelet, který můžeme vyhodnotit. Posledním případem z obrázku 44 je objekt tvořen spojením čtyřech objektů. Síť skeletu je totožná s případem 2, ale jednotlivé větve splňují podmínku minimálního poměru a po oddělení v průsečíku získáme tři skelety, které můžeme vyhodnotit.



Obrázek 44: Síť skeletu: (a) Vstupní obrázek. (b) Skelet obrázku.

Pokud nemají objekty kruhový nebo eliptický tvar, ale mají tvar pravidelný a jednotný, je nutná informace o tvaru ke správnému rozhodnutí jak rozdělit síť skeletu.

8 Rozpoznávání vláken směsné příze

V této části je popsána realizace postupu řešícího rozpoznávání typu vlákna ve směsných přízích. Realizovaný algoritmus je založen na použití metody maximální pravděpodobnosti popsané v kapitole 5.13.6. Jako vektoru příznaků je využito postupu uvedeného v kapitole 5.10.3, který vychází z řetězového kódu, na nějž se aplikuje rychlá Fourierova transformace, a po logaritmickém rozdělení spektra se počítají hodnoty v jednotlivých pásmech. Díky logaritmickému rozdělení se dosáhne lepšího rozlišení pro nízké frekvence, což je pro nás výhodné.

Používá se dvou množin příznaků, a to množiny trénovací a testovací. Trénovací množina slouží jako reprezentativní vzorek, na jehož základě se rozhoduje o zařazení objektu, respektive prvku do třídy. K tomu je určena množina testovací, ve které jsou uloženy příznaky rozpoznávaných objektů.

Výhodou použité metody maximální pravděpodobnosti je to, že bere v úvahu kromě středních hodnot příznaků i jejich rozptyly. Z vektorů příznaků je definováno normální rozložení pro danou třídu T_k , kterou v našem případě představuje některý druh vlákna, a to zobecněným rozložením pro vstupní vektor příznaků

$$P(\vec{x}|T_k) = \frac{1}{\sqrt{(2\pi)^p \det \Sigma}} e^{\left(-\frac{1}{2}(\vec{x}-\bar{x}_k)^T \Sigma^{-1}(\vec{x}-\bar{x}_k)\right)} \quad (54)$$

Σ je kovarianční matice (52) jejímiž prvky jsou rozptyly a kovariance (53).

Za předpokladu znalosti apriorní pravděpodobnosti všech tříd můžeme použít Bayesovského rozpoznávání, a tím rozhodnout o zařazení vektoru příznaků do příslušné třídy i ve sporných případech. Apriorní pravděpodobnost poskytuje informace o tom, jaké je celkové pravděpodobnostní zastoupení dané třídy. A pokud třídy T_1, \dots, T_n tvoří úplný systém, potom pro libovolný vektor příznaků \vec{x} platí

$$P(x) = \sum_{i=1}^n P(T_i)P(x|T_i), \quad (55)$$


$$P(T_k | x) = \frac{P(T_k)P(x|T_k)}{\sum_{i=1}^n P(T_i)P(x|T_i)} = \frac{P(T_k)P(x|T_k)}{P(x)} \quad \text{pro } k = 1 \dots n. \quad (56)$$

$P(x)$ představuje absolutní pravděpodobnostní hustotu rozložení, $P(T_i)$ je označena jako již zmíněná apriorní pravděpodobnost a $P(T_i/x)$ je výsledná aposteriorní pravděpodobnost.


Absolutní pravděpodobnostní hustota rozložení je nezávislá na zvolené třídě pro níž se provádí výpočet aposteriorní pravděpodobnosti. Můžeme tedy počítat bez této hodnoty. Výpočtem sice nezískáme přímo hodnoty aposteriorních pravděpodobností, ale při porovnání jednotlivých pravděpodobností získáme stejné výsledky.

Jako vstup algoritmu je použit obrázek příčného řezu směsné příze, která obsahuje dva typy vláken. Úkolem rozpoznávání je tedy přiřadit dané vlákno do jedné z dostupných tříd na základě tvaru jeho průřezu.

Ukázkový snímek řezu příze obsahující více typů vláken je na obrázku 45. Jedná se pouze o výřez, v plné velikosti je snímek uveden v příloze. Obrázek 46 představuje vizualizaci výsledků rozpoznávání. Typ vláken na základě třídy je odlišen barvou.



Obrázek 45: Řez přízí s více typy vláken.



Obrázek 46: Vizualizace výsledků rozpoznávání.

9 Měření fyzikálních vlastností nanovláken

Tato kapitola se zabývá automatickým měřením parametrů nanovláken pomocí počítačového zpracování obrazu. Nanovlákná jsou vyráběna postupem nazvaným elektrostatické zvlákňování s průměrem, který je o jeden až dva řády menší než u konvenčních textilních vláken.

Prezentované algoritmy a funkce vhodně využívají nástroje počítačového zpracování obrazu. Prvním měřeným parametrem je zaplnění, které je definováno jako poměr plochy vláken k ploše celkové. Další dva parametry jsou poloměr vláken a velikost děr. Změřené hodnoty jsou převedeny do reálných jednotek použitím známého měřítka. Získané informace mohou být použity k určení vlastností, jako je například filtrační schopnost daného materiálu.

9.1 Postup zpracování

Prvním krokem je segmentace obrazu. Jedná se o proces převodu na binární obraz, ve kterém jednotlivé objekty představují měřená vlákna. Parametr zaplnění určuje poměrné zastoupení plochy vláken v celé ploše snímku.

Realizovaný algoritmus využívá prahování, Cannyho hranový detektor, základní a pokročilé operace matematické morfologie. Segmentace obrazu je realizována pomocí algoritmu založeného na Cannyho hranovém detektoru. Operace skelet v modifikované podobě váženého skeletu je použita jako hlavní nástroj pro měření poloměru vláken. Řetězový kód je využit pro určení zakřivení skeletů jednotlivých vláken. Transformace rozvodí [15] umožňuje při měření velikosti děr jejich segmentaci.

Celý algoritmus je vyvinut ve vývojovém prostředí Matlab a skládá se z řady nezávislých funkcí. Umožňuje parametrizaci pomocí několika parametrů. Jejich správné nastavení je nezbytné pro přesné měření. Vykonávání programu je časově náročné a závisí především na velikosti zpracovávaných snímků, velikosti a typu objektů a hodnotách jejich parametrů.


9.1.1 Segmentace

Proces segmentace využívá v prvním kroku transformaci jasové stupnice prahování. Vlákna, která jsou blíž ke snímacímu zařízení (elektronový mikroskop) jsou světlejší a naopak

vlákna dále jsou tmavší (Obr. 47). To znamená vyšší hodnoty intenzity pro bližší vlákna. Vlákna nejsou rozložena do přesně oddělených vrstev podle jejich intenzity.

Celá vlákna nebo jejich části mají ve vzdálenějších vrstvách hodnotu intenzity blízkou intenzitě pozadí. Z toho vyplývá fakt, že histogram snímku reálných nanovláknenných struktur bude mít plochý průběh.


Z toho důvodu nelze získat požadovaný obraz s použitím pouze globálního prahování. V závislosti na nastavené hodnotě prahu segmentované binární obrazy obsahují některá vlákna kompletně, některá částečně a některá neobsahují.



Obrázek 47: Výřez snímku nanovláknenné struktury.

Proto je nutné použít pokročilejší postup. Cannyho hranový detektor je použit pro detekci hranic vláken. Ne všechny hranice jsou ale detekovány. Hrany v tmavých částech obrazu jsou detekovány nespolehlivě nebo vůbec, protože jim odpovídá malá změna obrazové funkce. Proto je využita znalost vzhledu vláken a analytická geometrie k doplnění chybějících hranic. Požadovaný výsledek je obrázek obsahující uzavřené oblasti definované získanými hranicemi. Předpokládá se pouze existence uzavřených hranic, které jsou zakončeny na hranici obrázku

nebo na jiné hranici. Avšak některé obsahují volné konce. Ty přísluší k částem vláken, jejichž intenzita v daném místě klesá. K tomu dochází v místech křížení vláken u vláken ve vzdálenějších (spodnějších) vrstvách. Koncové hranové body takových hran jsou nalezeny, upraveny morfologickými operacemi a prodlouženy pomocí krátkých přímkových úseků za účelem uzavření všech oblastí ohraničených těmito hranami. Znamená to tedy prodloužit nedokončenou hranu k okraji snímku, ukončit ji na další hraně nebo spojit dva volné konce přerušené hrany (Obr. 48).




Obrázek 48: Vizualizace hran ve vstupním obraze. Zelené hrany jsou získány pomocí hranového detektoru, modře jsou znázorněny prodlužující hranové segmenty a červené jsou spojnice dvou hran.

Získané oblasti jsou rozděleny do skupiny vláken nebo pozadí podle jejich intenzity. K tomuto účelu dostatečně poslouží vhodně naprahaný binární obrázek. Segmentovaný obrázek s objekty reprezentujícími celá vlákna je získán pomocí morfologických operací (Obr. 49). Binární eroze je využita ke zmenšení velikosti objektů v naprahaném obrázku a je použita k předejití výskytu chyb způsobených nižší kvalitou zpracovávaných obrázků, což je

patrné z rozmazaných hran. Dalším krokem je podmíněná dilatace. Binární dilatace zvětší objekty v binárním obraze s omezením představujícím hranice vláken. Některé oblasti mohou být špatně přiřazeny. Proto je segmentovaný obraz zpracován před aplikací podmíněné dilatace. Další možností je použití skeletu vláken pro aplikaci podmíněné dilatace místo použití eroze. Obrázek 49 ukazuje skelet vláken a jejich hranice. Jako prahování může být použito globální prahování, vhodnější je ale použít lokální prahování s vhodně zvolenou velikostí jádra.

Poté již lze určit první parametr, kterým je globální parametr zaplnění. Jedná se o poměr plochy vláken (počet pixelů objektů vláken) a celé plochy (celkový počet pixelů).




Obrázek 49: Skelet vláken a hranice vláken. Skelet je červený, hranice modré.

9.1.2 Poloměr vláken

Dalším parametrem je poloměr vláken. Jeho měření je založeno na použití váženého skeletu [14]. Je získán pomocí skeletu vážením pixelů skeletu, kdy se za jejich hodnotu dosadí index vrstvy, který je získán ze sekvenčního odstraňování jednotlivých vrstev.

Prvním krokem je aplikace skeletu na segmentovaném binárním obrázku. Dále je nutné skelet upravit. Obsahuje totiž tzv. „roztřepení“, která jsou způsobena malými nepravidelnostmi (details) na hranách v diskretním rastru. Tato roztřepení lze nejjednodušeji odstranit pomocí segmentace a filtrace na základě velikosti objektů. Nejdříve se najdou místa křížení, ve kterých se jednotlivé větve skeletu a roztřepení oddělí, a poté se odstraní malé objekty, které představují roztřepení. V některých případech se ale roztřepení vyskytují těsně vedle sebe a úseky skeletu jsou mezi nimi krátké a použitím tohoto postupu se kromě roztřepení odstraní celé úseky skeletu. Jednou možností řešení je roztřepení odstraňovat postupně.

Vhodnější je ale použití transformace tref či miň [15] se strukturním elementem z Golayovy abecedy nebo řetězového kódu. Odstraňování roztřepených větví skeletu vzniklých díky digitálního rastru probíhá pomocí postupných sumací relativního řetězového kódu. V obrázku 50 je uvedený příklad, kde skelet prochází zleva ze shora doprava dolů. Přibližně v polovině se vyskytuje roztřepení, které je potřeba odstranit. V případech malých roztřepení obklopených delšími úseky skeletu lze jejich odstranění provést hromadně pouze s informací o velikosti jednotlivých objektů.



Obrázek 50: Detail skeletu s roztřepením a vypsáním relativním řetězovým kódem.

V tabulce 3 jsou uvedeny relativní řetězové kódy části skeletu a roztřepení. Řetězový kód skeletu, respektive sumace po trojicích, je uveden v sudých řádcích. Nakonec získáme dvě výsledná čísla. Porovnáním jejich hodnot již lze jednoznačně rozhodnout, která větev představuje skelet a která ne. Větev s větší výslednou absolutní hodnotou není součástí skeletu a představuje roztřepení. Podobným postupem lze vyšetřovat místa skeletu pro vhodnost měření průměrů, což se týká především metody využívající váženého skeletu.

(1)	0	-1	1	-1	1	0	-1	0	0	0	-1	1	-1	0	0
(2)	0	-1	1	-1	1	0	-1	1	0	0	-1	1	-1	1	0

(1)	0	-1	1	0	0	-1	-1	0	-1	0	-1	0	-1
(2)	0	-1	1	0	0	0	0	1	-1	0	-1	1	0

(1)	0	0	1	-1	-2	-2	-2	-1	-2	-1	-2
(2)	0	0	1	0	0	1	0	0	-2	0	0

(1)	1	0	-2	-5	-6	-5	-5	-4	-4
(2)	1	1	1	1	1	1	-2	-2	-2

(1)	-1	-7	-13	-16	-16	-14	-13
(2)	3	3	3	3	0	-5	-6


(1)	-21	-36	-45	-46	-43
(2)	9	9	6	-2	-11

(1)	-102	-127	-134
(2)	24	13	-7

(1)	-363	...	spur
(2)	30	...	skeleton

Tabulka 3: Relativní řetězové kódy a jejich postupné sumace.

Poté je upravený skelet transformován do skeletu váženého. Lze toho dosáhnout aritmetickým součinem skeletu a vzdálenostní transformací (Obr. 51) segmentovaného obrazu. Obraz skeletu je prakticky použit jako maska aplikovaná na obraz vzdálenostní transformace. Vzdálenostní transformace je dána jako minimální vzdálenost objektového pixelu od pozadí a je použita na segmentovaném obraze (Obr. 52).



Obrázek 51: Vzdálenostní funkce zobrazená v teplotní stupnici.

Tvar skeletu představuje podélný tvar objektu, hodnoty váženého skeletu nabízí informaci o příčném tvaru objektu. Mohou být použity jako hodnoty lokálního poloměru vlákna v daném místě. Na rovnějších úsecích vláken bez velkých zakřivení je měření přesné na rozdíl

od úseků velmi zakřivených. Proto je také využito hodnocení zakřivení vláken k dosažení přesnějších výsledků.




Obrázek 52: Segmentovaný obrázek. Binární obrázek je označovaný.

K tomuto účelu je využit řetězový kód. Pro naše účely je využit řetězový kód skeletu. Zakřivení celého vlákna nebo jeho části může být určeno jako rozdíl hodnot kódu na začátku a na konci příslušného segmentu.

Další možností je úprava absolutního řetězového kódu na kód relativní. Hodnoty relativního řetězového kódu skeletu vláken dávají informaci o lokálním zakřivení. Je realizována sumace hodnot na definované velikosti okolí. Tato velikost je nastavena v závislosti na velikosti měřítka.

9.1.3 Velikost děr

Parametr velikost děr poskytuje informaci o míře filtračních schopností daného materiálu. Parametr zaplnění dává také určitou informaci o filtrační schopnosti, ale zpracování obrázku z hlediska děr poskytne přesnější výsledek. Pro praktické využití jsou jednotlivé díry popsány hodnotami poloměru maximálně vepsaných kružnic. Ty představují maximální velikost částice, která může projít nanovlákným filtrem. Postup stanovení poloměru je částečně podobný postupu měření poloměru vláken. Negativní obrázek segmentovaného obrázku vláken je využit jako obrázek děr a je na něm aplikována operace váženého skeletu (Obr. 53).




Obrázek 53: Skelet děr a hranice děr. Skelet je červený, hranice jsou modré.

Avšak ne všechny hodnoty váženého skeletu jsou použity ve srovnání s měřením poloměru vláken. Následně lze rozhodnout pro jednu ze dvou možností. První z nich je popsat každou díru jednou hodnotou představující poloměr maximálně vepsané kružnice. Druhou možností je použití transformace rozvodí, kterou lze některé oblasti rozdělit do menších podoblastí (Obr. 54). Myšlenka spočívá v umístění vodního zdroje do každého lokálního minima v inverzní vzdálenostní transformaci. Při následném podmíněném zaplávání se

vytvářejí hranice v místech styku dvou a více zdrojů. Tyto hranice se nazývají linie rozvodí a jsou použity k rozdělení oblastí.

Transformaci rozvodí je vhodné použít v případech, kdy se v obraze vyskytují díry, jejichž tvar se velmi liší od konvexního obalu, a je tudíž nutné takovým oblastem určit více vepsaných kružnic. K rozdělení některých děr je možné použít i další morfologické operace.

Maximální hodnota váženého skeletu v dané oblasti nebo podoblasti poté představuje poloměr maximálně vepsané kružnice odpovídající maximální velikosti částice, která v daném místě filtrem projde.




Obrázek 54: Segmentovaný obrázek děr po aplikaci transformace rozvodí. Obrázek je označován.

9.2 Výsledky

Realizovaný měřicí algoritmus je aplikován na obrázku 47. Následující obrázky demonstrující popsany postup jsou z důvodu lepší přehlednosti pouze výřezy. Obrázky 55 a 56 představují histogramy poloměru vláken a velikost děr (poloměry vepsaných kružnic)


odpovídající celému obrázku. Měřené hodnoty jsou převedeny do reálných jednotek pro odstranění závislosti na měřítku a za účelem jejich použitelnosti v praxi. Měřítka je k dispozici z nastavení snímacího zařízení, kterým je elektronový mikroskop. Průměrná hodnota průměru vláken je v daném obrázku $120,5 \text{ nm}$. Průměrná hodnota poloměru vepsaných kružnic jednotlivých oblastí děr je $214,7 \text{ nm}$. První sloupec ve sloupcovém grafu histogramu děr (Obr. 56) odpovídá malým podoblastem děr získaných po aplikaci segmentace pomocí transformace rozvodí. Je to způsobeno nerovnými hranicemi obsahujícími malé detaily v digitálním rastru. Proto jsou výstupy filtrovány a tyto hodnoty jsou odstraněny. Průměrná hodnota poloměru maximálně vepsaných kružnic poté vzroste na $227,4 \text{ nm}$ a sníží se také směrodatná odchylka na hodnotu $110,4 \text{ nm}$. Přesnost výsledků je částečně snížena proměnným zvětšením v důsledku perspektivy a ztráty prostorové informace. Na snímcích nanovláken je sejmuto více vrstev v závislosti na hloubce ostrosti. Jedná se tedy o klasický problém měření rozměru při proměnné předmětové vzdálenosti. V důsledku malé hloubky ostrosti zle tuto nepřesnost považovat za přijatelnou. Hodnoty gradientu na hranách vláken by bylo možné použít pro případnou korekci. Vyhodnocované obrázky mají ale bohužel relativně nízkou kvalitu a korekční funkci nelze vytvořit, protože není k dispozici kalibrační obraz.



Obrázek 55: Histogram poloměrů vláken.

velikost obrazových dat	2000 x 2000 pixelů
parametr zaplnění	40,8 %
aritmetický průměr poloměru vláken	117,7 nm
směrodatná odchylka poloměru vláken	67 nm
rozptyl poloměru vláken	4489,2 nm ²

Tabulka 4: Výsledky měření vláken.



Obrázek 56: Histogram velikostí děr (poloměr vepsaných kružnic).

velikost obrazových dat	2000 x 2000 pixelů
aritmetický průměr velikosti děr (poloměr vepsané kružnice)	216,7 nm
směrodatná odchylka velikosti děr	124,7 nm
rozptyl velikosti děr	15544,5 nm ²

Tabulka 5: Výsledky měření velikosti děr.

10 Dynamické měření parametrů příze

Hodnocení příze stávajícími přístupy probíhá pouze na několika vybraných úsecích příze, a takto získaná data se používají pro statistický odhad parametrů příze celé. Existují komerční přístroje nebo lze přízi hodnotit přímo při výrobě nebo zpracování pomocí on-line snímání.

K základním měřeným parametrům příze, kromě mechanicko-fyzikálních vlastností, délkové hmotnosti a zákrutů, patří hmotová nestejnoměrnost příze a sledování vad příze. Díky dlouholeté tradici a zkušenostem je dnešní vyhodnocení těchto parametrů velmi propracované. Zhruba od 90. let minulého století, díky vývoji optických snímačů, je možnost komerčního vyhodnocení příze obohacena o další parametry přízi, jako je chlupatost příze, průměr příze, tvar příze a nečistoty v přízi. Lze sledovat také přítomnost cizorodých příměsí v surovině a v přízi v průběhu výroby, ale také v laboratoři.

Výstupem některých laboratorních přístrojů je na základě proměřené příze simulovaný vzhled příze na desce, v pletenině nebo tkanině inspirovaný dříve používaným hodnocením vzhledu příze a nečistot podle etalonů vzhledu.

Tato kapitola představuje metodu optického vyhodnocování parametrů příze. Příze je snímána při převíjení digitální řádkovou kamerou a získaná obrazová data jsou zpracována algoritmy počítačové analýzy obrazu. Tato metoda umožňuje vyhodnotit většinu požadovaných parametrů příze a to v celé délce hodnocené příze. Není tedy nutné statisticky odhadovat parametry příze na základě několika lokálních měření.


Dalším přínosem, na rozdíl od stávajících komerčních přístrojů, je možnost reálného hodnocení více rovnoběžných úseků příze vedle sebe na ploše. To umožňuje snímání na speciálně navrženém převíjecím zařízení (Obrázek 57), popsaném v [38]. Tato přednost posouvá možnosti hodnocení příze. Pozornost byla zaměřena na posouzení možnosti zefektivnit hodnocení příze pro vědecké účely. Pro komerční oblast je snahou hledat bohatší možnosti hodnocení příze na jednom zařízení, než dosud komerční zařízení nabízejí.

10.1 Snímací soustava


Ke snímání navinuté příze je používána řádková kamera. Hlavní rozdíl mezi kamerami řádkovými a plošnými je v typu použitého snímače. Řádková kamera je na rozdíl od plošné kamery vybavena snímačem s fotocitlivými elementy uspořádanými v jednorozměrném poli.

Tyto kamery jsou běžně využívány ke snímání objektů pohybujících se konstantním směrem, například pásových dopravníků. Výstupem kamery jsou potom obrázky složené z předem definovaného počtu řádků. Aby nedocházelo ke ztrátě nebo duplicitám obrazové informace, je potřeba synchronizace frekvence kamery s rychlostí pohybu snímaného objektu. Tím se rozumí nastavení řádkové snímací frekvence tak, aby se sousední řádky nepřekrývaly, ale současně mezi nimi nevznikala mezera. V případě proměnné rychlosti pohybu objektů před kamerou je nutné frekvenci kamery měnit pomocí externích řídicích pulzů.

Na zařízení jsou snímány různé druhy převíjených přízí. Ty se převíjí z jedné cívky na druhou přes bubnový zásobník (Obrázek 59), kde jsou snímány. Použita je řádková kamera firmy Basler, model Sprint spL2048-39km s dvouřádkovým CMOS snímačem s rozlišením 2048 pixelů [39]. Maximální řádková frekvence kamery je 38,6 kHz. Z důvodu požadavku velké přesnosti a minimalizace optických vad, byla kamera vybavena speciálně navrženou optikou. Ta se skládá ze čtyř členů: objektiv, mezikroužek o tloušťce 75 mm, adaptér a samostatná clona. Řádkové kamery se většinou doplňují řádkovými osvětlovači typu LED nebo laser, v našem případě se jedná o dvojici řádkových osvětlovačů Büchner POWER-LINE-1TE (red 625 nm 30°) s fokusovacími čočkami (D25mm 1T) [40].




Obrázek 57: Snímek zařízení.




Obrázek 58: Bližší pohled na snímací soustavu.

10.2 Postup vyhodnocení


Získaná obrazová data lze použít pro získání hodnot některých parametrů charakterizujících průměry, chlupatost, sklon a pravidelnost ovinků nebo detekovat lokální vady příze. Vzhledem k průběhu jasového profilu (Obrázek 61) lze pro měření průměru příze předzpracovat snímky prahováním a použitím dalších morfologických operací k odstranění šumu a odstávajících vláken. Poté lze již měřit průměr příze (Obrázek 62). Pro přesné hodnocení chlupatosti je nutné splnit požadavek přesnosti. Ten je stanoven minimální tloušťkou vlákna. V případě bavlny to může být minimálně $10\ \mu\text{m}$, obecně může tloušťka vláken začínat od $1\ \mu\text{m}$. Použitá snímací soustava poskytovala přesnost $0,077\ \text{mm}$. Z toho vyplývá, že nasnímané obrázky nejsou zcela vhodné pro hodnocení chlupatosti a je potřeba použít kameru s vyšším rozlišením, popř. jinou optiku. Dalším problémem při hodnocení chlupatosti byl nedostatečný kontrast vláken vzhledem k nehomogennímu pozadí, které je v místech lamel světlejší v důsledku ulpívání prachových částic. Ty vznikají odíráním příze při převíjení. Při hodnocení ovinků se ukazuje nutnost nastavit snímání jinak, aby byla lépe prokreslena struktura příze a bylo možné segmentovat jednotlivá vlákna. Toho lze dosáhnout změnou osvětlení nebo parametrů snímání.




Obrázek 59: Bubnový zásobník příze.




Obrázek 60: Snímek příze na zásobníku.



Obrázek 61: Jasový profil.




Obrázek 62: Měření průměru příze.




Obrázek 63: Snímek příze na zásobníku.



Obrázek 64: Binární obrázek příze bez chlupů.



Obrázek 65: Binární obrázek chlupů příze s konturami jednotlivých přízí.



Obrázek 66: Vykreslení nalezených obrysů příze a vláken do vstupního obrázku.

Zpracování obrazových dat se dá rozdělit do dvou hlavních částí: nalezení těla příze a vláken. Vlákna se potom podle jejich umístění vzhledem k nalezeným konturám příze dají rozdělit na vlákna odstávající, tedy chlupy, a vlákna tvořící ovinky.

První použitou operací je transformace jasové stupnice prahování. Jejím výstupem je binární obrázek s objekty reprezentující těla přízí (Obrázek 64). Tento obrázek se po několika dalších morfologických úpravách dá již použít pro měření lokálních průměrů (Obrázek 62). Tyto hodnoty je pro praktické použití vhodné upravit například pomocí klouzavého průměru a poté statisticky zpracovat. Pro detekci vláken je použit hranový operátor. Jeho výstup je opět několika operacemi upraven, až jsou nakonec získány objekty představující jednotlivá vlákna (Obrázek 65). Se znalostí kontur jednotlivých přízí je možné obrázek s vlákny dále zpracovávat, odstávající vlákna jsou potom totiž jednoznačně odlišena od vláken zbylých. Pro kontrolu správnosti postupu jsou nalezená vlákna a kontury přízí vykreslena do vstupního obrázku (Obrázek 66).

Pro určení *plošné nestejnoměrnosti*⁷⁴ [41] lze použít tzv. *variogram*. Ten představuje míru rozdílnosti, tedy variance, protože vyjadřuje prostorovou závislost na prostorové náhodné proměnné nebo na stochastickém procesu a lze ho spočítat jako

⁷⁴ anglicky *surface unevenness*

$$\begin{aligned} 2\Gamma(x, y) &= \text{var}(Z(x) - Z(y)) = \\ &= E(Z(x) - Z(y))^2 - \{E(Z(x) - Z(y))\}^2. \end{aligned} \quad (57)$$

$\Gamma(x, y)$ se nazývá *semivariogram* a rozdíl $(y - x)$ se označuje jako *lag* a představuje *směrový vektor*. Upravený vztah pro semivariogram je potom

$$\Gamma(\text{lag}) = \frac{1}{2} (E(Z(x) - Z(x + \text{lag}))^2 - \{E[Z(x) - Z(x + \text{lag})]\}^2). \quad (58)$$

Jako vstup bude použit nasnímaný obraz, a potom se pro rovnoměrně rozmístěné body vyjádří hodnoty směrového vektoru jako násobky ve směru horizontálním – řádků, vertikálním – sloupců a na diagonále. Zprůměrováním těchto tří získaných směrových semivariogramů získáme *všesměrový semivariogram*⁷⁵. V případě, že je náhodné pole nestacionární se používá tzv. *centrovaný semivariogram*, který je určen jako

$$G(\text{lag}) = \frac{1}{2N(\text{lag})} \sum_{i=1}^{N(\text{lag})} [Z_c(x) - Z_c(x + \text{lag})]^2, \quad (59)$$

kde $Z(x)$ představuje průměrnou hodnotu (stupeň šedi), $N(\text{lag})$ je počet dvojic bodů vzdálených o směrový vektor a $Z_c(x)$ je *centrovaná* hodnota (stupeň šedi) určená v daném místě jako


$$Z_c(x) = Z(x) - \frac{\sum_{i=1}^{n(x)} Z(x)}{n(x)}. \quad (60)$$

Před vlastním výpočtem se vstupní obraz rozdělí na čtverce, jejichž velikost strany odpovídá tzv. *kroku*. V každém ze čtverců se stanoví průměrná hodnota (stupeň šedi) $Z(x)$, se kterou se dále počítá.

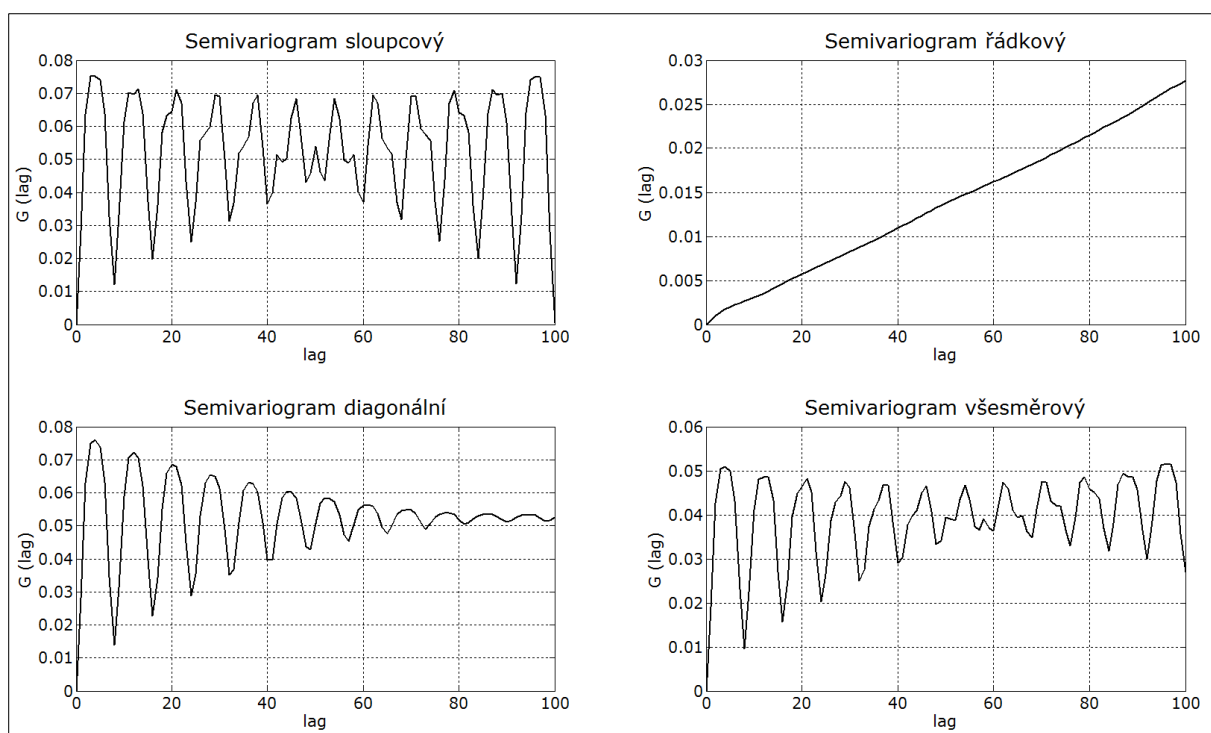
Na obrázku 68 jsou zobrazeny jednotlivé semivariogramy pro vstup odpovídající obrázku 67 s hodnotou kroku 10.

⁷⁵ *var* představuje rozptyl, E je střední hodnota

⁷⁶ anglicky *omnidirectional variogram*



Obrázek 67: Příze na zásobníku.



Obrázek 68: Semivariogramy.

Závěr

V disertační práci jsou řešeny aplikace zpracování obrazu textilních struktur pomocí počítačového zpracování obrazu. Popsané algoritmy řeší konkrétní problémy vyskytující se při jejich zpracování. Výstupem práce jsou realizace vytvořené ve vývojových prostředích od firmy National Instruments nebo v programovacím prostředí Matlab.

Jedním typem zpracovávaných textilií byly příčné řezy. Byly realizovány algoritmy provádějící segmentaci obrazu, detekci vláken a rozpoznávání typu vláken ve směsných přízích. Tyto postupy nelze plně automatizovat ve smyslu tvorby obecného přístupu vyhovujícímu všem typům vláken. Vždy je potřeba alespoň minimální uživatelský vstup ve smyslu volby typu vlákna. Čím složitější je zpracování, tím méně univerzální je celý postup. Jako vstupní data slouží kromě digitálních obrazů i vstupní parametry jednotlivých algoritmů. Úspěšnost algoritmů závisí především na kvalitě obrazových dat. Pro řezy s vlákny kruhového průřezu lze využít algoritmus detekující objekty vláken pomocí Houghovy transformace. Jedná se o robustní přístup, který si často úspěšně poradí i s méně kvalitními vstupními daty. Je ale výpočetně náročný a prakticky nepoužitelný pro vlákna, jejichž tvar nelze popsat analyticky. Tento postup řeší i případy, kdy se vlákna dotýkají a jsou v obraze reprezentována jedním objektem. Další možností jak oddělit dotýkající se vlákna realizuje postup založený na váženém skeletu. Je to pokročilejší postup s možností parametrizace na rozdíl od segmentace pomocí transformace rozvodí. U směsných přízí bylo realizováno rozpoznávání typů vláken metodou maximální pravděpodobnosti. Tento postup vyžaduje uživatelský vstup v podobě vytvoření trénovací množiny učením. Poté již rozpoznávání probíhá zcela automaticky. Na testovaných řezech byla úspěšnost rozpoznávání téměř stoprocentní.

Měření fyzikálních parametrů nanovláken je vhodnou úlohou pro vyhodnocení jejich digitálního obrazu pomocí počítačového zpracování. Popsané metody nejdříve předzpracovávají obraz několika přístupy, a poté provádějí zpracování. Parametr zaplnění se spočítá jednoduše jako poměr ploch vláken k ploše celkové. K počítání průměru vláken je popsáno několik postupů. Dva z nich využívají morfologické operace skeletu. Jako velmi dobře využitelný prostředek se jeví řetězový kód. Lze ho použít v několika případech ve formě relativního řetězového kódu. Kódu absolutního bychom použili například při vyhodnocování převažujícího směru vláken. Hodnoty měřených parametrů jsou získány v pixelech. Pro měření v reálných jednotkách je provedena kalibrace. K té je použito nastavení snímání elektronovým mikroskopem v podobě měřítka. Pro přesnost metod je podstatná kvalita a rozlišení

vyhodnocovaných dat a především vhodnost nastavení parametrů použitého postupu. Výhoda metody spočívá v možnosti měření poloměru vláken i v místech křížení pro vlákno ve vrchní vrstvě.

Dynamické měření parametrů příze představuje nový přístup ve srovnání se současnými přístupy. Umožňuje získat a hodnotit reálný obraz plošné struktury textile. Dalšími výhodami je plná automatizace, eliminace subjektivních vlivů, rychlost vyhodnocení a možnost jednoduše vyhodnocovat velký vzorek několika úseků příze najednou. Tím může být dosaženo vyšší přesnosti oproti ručnímu vyhodnocování díky statisticky nesrovnatelně většímu množství změřených hodnot.

Manuální hodnocení probíhá na mikroskopických obrazech snímajících úseky délky $1,25\text{ mm}$. Dle současné normy je pro hodnocení příze použito sto obrazů, na jejichž sejmutí je potřeba přibližně půl hodiny a další čas pro jejich zpracování. Uvedená metoda dynamického snímání a vyhodnocování příze probíhá plně automaticky. Rychlost snímání a vyhodnocování je u této metody omezena pouze použitým hardwarem a výpočetní náročností algoritmů. Je tedy zřejmé, že dosažená rychlost a efektivita je mnohonásobně vyšší než u zpracování mikroskopických obrazů vytvářených manuálně. Oproti tomu mikroskopická metoda dosahuje v současné době řádově vyšší přesnosti. Ta se dá zvýšit použitím snímací soustavy disponující vyšší rozlišovací schopností.

Na převíjecím zařízení se zásobníkem bylo také realizováno snímání přástu. Ten ale nebyl navinut na zásobník a byl pouze převíjen. Z tohoto důvodu bylo celé zařízení upraveno. Kvůli snížení velikosti záběru kamery téměř o jeden řád bylo dosaženo mnohem vyšší rozlišovací schopnosti než v případě příze. Při stejné datové propustnosti musela být ale rychlost převíjení v závislosti na tom snížena. Analýzou obrazu byla ověřena možnost měření poloměru a detekce chlupů (odstávajících vláken). Za účelem hodnocení struktury těla se osvětlení ukázalo jako ne zcela vhodné. Nebylo tedy možné detekovat vlákna, která mají za úkol zajistit soudržnost přástu (ovinky). Jiný typ osvětlení nebyl k dispozici. Této problematice nebyl věnován větší prostor a je uvedena pouze jako ukázání možností daného zařízení.

Reference

- [1] ZIABARI M., MOTTAGHITALAB V., MCGOVERN S.T.: *A New Image Analysis Based Method for Measuring Nanofiber Diameter*. [online][cit. 2011-06-05]. Dostupné na www: <<http://www.nanoscalereslett.com/content/2/12/597/>>
- [2] NECKÁŘ B.: Yarn Hairiness, Part 1: *Theoretical model of yarn hairiness*. 7th International conference Strutex. Technical University of Liberec, Czech Republic 2000, ISBN: 80-7083-442-0
- [3] NECKÁŘ B.: *Příze. Tvorba, struktura, vlastnosti*. SNTL Praha 1990, ISBN 80-03-00213-3
- [4] KŘEMENÁKOVÁ D.: *Doporučený postup tvorby příčných řezů. Měkké a tvrdé řezy*. Interní norma 46-108-01/01. Dostupné z: <http://centrum.tul.cz/centrum/centrum/5Normy/IN%2046-108-01_01.pdf>
- [5] JIRSÁK O., LUKÁŠ D., SANETRŇÍK F., MARTINOVÁ L., CHALOUPEK J., RŮŽIČKOVÁ J., KOŠŤÁKOVÁ E., HRŮZA J.: *Výroba a vlastnosti nanovláken*. Dostupné z: <<http://webcache.googleusercontent.com/search?q=cache:wFBEPd5x5wEJ:www.ft.tul.cz/depart/knt/nove/dokumenty/studmaterialy/ntt/nanoact.ppt+&cd=1&hl=cs&ct=clnk&gl=cz>>
- [6] MORTON W.J.: *Method of Dispersing Fluids*, US Patent No. 705 691, 1902
- [7] FISCHER J.: *Optoelektronické senzory a videometrie*. Vydavatelství ČVUT, 2005. 143 s. ISBN 80-01-02525-X
- [8] DOLEČEK, J.: *Moderní učebnice elektroniky 3. díl – Optoelektronika a optoelektronické prvky*. BEN Praha 2005, ISBN 80-7300-184-5

- [9] *Foveon. X3 technology: Direct Image Sensors* [online]. 2010, [cit. 2012-10-28]. Dostupné z <<http://www.foveon.com/article.php?a=67>>
- [10] SEDLÁČEK M., ŠMÍD R.: *MATLAB v měření*. skriptum ČVUT, Praha 2004, ISBN 80-01-02851-8
- [11] DUŠEK F.: *MATLAB a SIMULINK. Úvod do používání*. skriptum Univerzita Pardubice, 2002, ISBN 80-7194-475-0
- [12] ŽÍDEK, J.: *Grafické programování ve vývojovém prostředí LabVIEW*. VŠB-TU Ostrava, 2005, [cit. 2012-05-07]. Dostupné na [www](http://autnt.fme.vutbr.cz/lab/FAQ/labview/VI_Skripta.pdf): <http://autnt.fme.vutbr.cz/lab/FAQ/labview/VI_Skripta.pdf>
- [13] VLACH, J. A KOL.: *Začínáme s LabVIEW*. BEN Praha 2008, ISBN 978-80-7300-245-9;
- [14] SONKA M., HLAVAC V., BOYLE R.: *Image Processing, Analysis, and Machine Vision*. CL-Engineering 2005, ISBN-10: 049508252X, ISBN-13: 978-0495082521
- [15] HLAVÁČ V., SEDLÁČEK M.: *Zpracování signálů a obrazů*. Vydavatelství ČVUT, 2005. 255 s. ISBN 80-01-03110-1
- [16] DAVIES E. R.: *Machine Vision, 3rd Edition*. Elsevier 2005, ISBN 0-12-206093-8
- [17] GONZALES R. C., WOODS, R. E.: *Digital Image Processing*. Prentice Hall 2002, ISBN 0-201-18075-8
- [18] JÄHNE B.: *Digital Image Processing*. 6th Edition, Springer 2005, ISBN 3-540-24035-7
- [19] PRATT, W. K.: *Digital Image Processing*. 3rd Edition, John Wiley & Sons 2001, ISBN 0-471-37407-5

- [20] DOBEŠ M.: *Zpracování obrazu a algoritmy v C#*. BEN Praha 2008, ISBN 978-80-7300-233-6
- [21] CANNY J.: *A Computational Approach to Edge Detection*. In: IEEE Trans. Pattern Analysis and Machine Intelligence, s. 679-698, 1986, [cit. 2012-05-07]. Dostupné na www: <http://perso.limsi.fr/Individu/vezien/PAPIERS_ACS/canny1986.pdf>
- [22] MATOUŠEK V.: *Rozpoznávání*. Skriptum. [cit. 2012-01-20]. Dostupné z <<http://www.kiv.zcu.cz/studies/predmety/kro/Skriptum/K5.ps>>
- [23] TAYLOR C. C., MICHIE D., SPIEGELHALTER D.J.: *Machine Learning, Neural and Statistical Classification*. Citováno září 2012. Dostupné z <<http://www.maths.leeds.ac.uk/~charles/statlog/whole.pdf>>
- [24] SVOBODA T., KYBIC J., HLAVAC V.: *Image Processing, Analysis & and Machine Vision - A MATLAB Companion*. CL-Engineering 2007, ISBN-10: 0495295957, ISBN-13: 978-0495295952
- [25] ŠONKA M., HLAVÁČ V.: *Počítačové vidění*. Praha, Grada, 1992. ISBN 80-85424-67-3
- [26] MATELA L.: *Rozpoznávání druhů stromů podle tvarů jejich listů*. [online] K7 – vědecko populární časopis Fakulty mechatroniky TU v Liberci, [cit. 2011-11-09]. Dostupné na www: <http://k7.vslib.cz/files/k7_04_2.pdf>. ISSN 1214-7370
- [27] *The Mathworks - Image Processing – Demos and Webinars*. [online]. 2009 [cit. 2012-01-20]. Dostupné na www: <<http://www.mathworks.com/applications/imageprocessing/index.html>>
- [28] *Morphology-based Operations*. [online]. 2009 [cit. 2011-12-12]. Dostupné na www: <<http://www.ph.tn.tudelft.nl/Courses/FIP/noframes/fip-Morpholo.html#Heading9>>

- [29] *Contour Representations - Chain code*. [online]. 2009 [cit. 2011-10-01]. Dostupné na www:
<<http://www.ph.tn.tudelft.nl/Courses/FIP/noframes/fip-Contour.html#Heading26>>
- [30] FISHER R., PERKINS S., WALKER A. AND WOLFART E.: *Image processing learning resources*. [online]. 2009 [cit. 2010-03-05]. Dostupné na www:
<http://homepages.inf.ed.ac.uk/rbf/HIPR2/hipr_top.htm>
- [31] BOCK RUDOLF K.: *Hough Transform*. [online]. 2012 [cit. 2012-09-04]. Dostupné na www:
<http://ikpe1101.ikp.kfa-juelich.de/briefbook_data_analysis/node122.html>
- [32] ČASTOVÁ N., KOZUBEK T.: *Integrační transformace. Skriptum*. [cit. 2012-06-02]. Dostupné na www: <http://www.am.vsb.cz/studium/integralni_transformace/>
- [33] FARID H.: *Fundamentals of Image Processing*. Dartmouth Computer Science Department, Hanover (USA), text, [cit. 2013-08-07]. Dostupné z:
<<http://www.cs.dartmouth.edu/~farid/tutorials/fip.pdf>>
- [34] *IRAFM OSU – Image processing*. [cit. 2013-06-06]. Dostupné z:
<http://irafm.osu.cz/en/c94_image-processing>
- [35] ŠPANĚL M., BERAN V.: *Obrazové segmentační techniky*. skriptum VUT Brno 2005, [cit. 2011-01-10]. Dostupné z:
<<http://www.fit.vutbr.cz/~spanel/segmentace/>>
- [36] DUDA R. O., HART P. E.: *Use of the Hough Transformation to Detect Lines and Curves in Pictures*. In: Comm. ACM, Vol. 15, s. 1-15 (January, 1972), [cit. 2013-05-06]. Dostupné z: <<http://www.ai.sri.com/pubs/files/tn036-duda71.pdf>>
- [37] *Zaplnění příže. Přímá metoda a metoda Secant*. Interní norma č.22-103-01/01. TUL, Fakulta textilní

- [38] BERAN L., ŠRÁMEK R., VYŠANSKÁ M., HORČIČKA J., KOUKOLÍKOVÁ L., HORÁLEK R., JELÍNEK I.: *Optical Evaluation of a Yarn Being Continuously Wound on the Surface*. 16th International Conference Structure and Structural Mechanics of Textiles, STRUTEX 2009
- [39] *Technická dokumentace ke kameře Basler spL2048-39kc*: Dostupné z <http://www.baslerweb.com/products/sprint.html?model=259>
- [40] *Technická dokumentace k osvětlovači Büchner POWER-LINE-ITE*: Dostupné z <http://buechner.exportpages.com/productdetail/1094281077-1.htm>
- [41] EVA MOUCKOVA, PETR URSINY AND PETRA JIRASKOVA (2010): *Surface Unevenness of Fabrics*. Woven Fabric Engineering. Polona Dobnik Dubrovski (Ed.), ISBN: 978-953-307-194-7, InTech, Available from: <http://www.intechopen.com/books/woven-fabric-engineering/surface-unevenness-of-fabrics>
- [42] KRUPINCOVÁ G.: *Chlupatost a průměry přízí*. Disertační práce. TU v Liberci 2012.

Seznam publikací a dalších výsledků

- [1] HOLADA M., KOPETSCHKE I., PIRKL P., MATELA L., HORČIČKA J., ŠTILEC J.: *The prototype of human – robot voice interactive control system*, 16th Czech-German Workshop on Speech Processing 2006, Prague
- [2] HOLADA M., KOPETSCHKE I., PIRKL P., PELC M., MATELA L., HORČIČKA J., ŠTILEC J.: *Voice Interactive Control System for Robots with Distributed Components*, 21st European Conference on Modelling and Simulation (ECMS 2007), Praha
- [3] HOLADA M., PELC M., KOPETSCHKE I., PIRKL P., MATELA L., HORČIČKA J., ŠTILEC J.: *The Prototype of Human – Robot Interactive Voice control system*, International Conference on Informatics in Control, Automation and Robotics (ICINCO 2007), Angers (France), vol. RA-1, pp. 307-310, ISBN: 978-972-8865-83-2- uvedeno ve Scopus
- [4] HORČIČKA J.: *Separace vláken v příčných řezech přízí*, Sborník technických zpráv VCT II, sekce C, 2008, ISRN - VCT2/C-RMM/TZ - 08/001/CZ.
- [5] HORČIČKA J., HORÁLEK R.: *Dynamické měření parametrů příze pomocí počítačového zpracování obrazu*, Sborník technických zpráv VCT II, sekce C, 2009, ISRN - VCT2/C-RMM/TZ - 09/001/CZ.
- [6] HORČIČKA J.: *Měření fyzikálních vlastností nanovláken pomocí počítačového zpracování obrazu*, Sborník technických zpráv VCT II, sekce C, 2009, ISRN - VCT2/C-RMM/TZ - 09/001/CZ.
- [7] BERAN L., ŠRÁMEK R., VYŠANSKÁ M., HORČIČKA J., KOUKOLÍKOVÁ L., HORÁLEK R., JELÍNEK I.: *Optical Evaluation of a Yarn Being Continuously Wound on the Surface*, 16th International Conference Structure and Structural Mechanics of Textiles, STRUTEX 2009.

- [8] HORČIČKA J.: *Physical Properties Determination of Nanofibers*, 16th International Conference Structure and Structural Mechanics of Textiles, STRUTEX 2009.
- [9] HORČIČKA J., HORÁLEK R.: *Nástroj pro hodnocení nanovláknenných obrazů (Nimet)*, R – Software, JC - Počítačový hardware a software, 2010,
RIV/46747885:24220/10:#0001593
- [10] BERAN L., HORČIČKA J., HORÁLEK R., ŠRÁMEK R.: *Hodnocení textilních meziproduktů*, Sborník technických zpráv VCT II, sekce C, 2010, ISRN - VCT2/C-RMM/TZ - 10/001/CZ.
- [11] HORČIČKA, J.: *Physical properties measurement on nanofiber images*. Electronics, Control, Measurement and Signals (ECMS), 2011 10th International Workshop on 1-4 (2011).
- [12] ŠRÁMEK, R., BERAN, L., KOUKOLÍKOVÁ, L., HORČIČKA, J.: *Způsob zjišťování vzhledových vlastností příze v ploše a zařízení k jeho provádění* - PV 2011-788, 2011


Přílohy

A Detekce vláken pomocí Houghovy transformace


Na obrázku 69 je mikroskopický snímek příčného řezu hedvábím, na který je aplikován algoritmus hledající jednotlivá vlákna v příčném řezu s využitím Houghovy transformace (kapitola 6). Na obrázku 70 je snímek předzpracován, na dalším obrázku je vizualizován akumulátor transformace projekcí maxim do obrázku. Z obrázku tedy nejsou zřejmé hodnoty poloměrů nalezených kružnic. V následující tabulce 6 jsou vypsány jejich parametry.



Obrázek 69: Příčný řez hedvábím.



Obrázek 70: Binární obrázek získaný předzpracováním z obrázku 69. Obrázek je invertován.




Obrázek 71: Akumulátor Houghovy transformace odpovídající vstupnímu obrázku 69.

datum a čas: 02-May-2012 17:41:25			
jméno zpracovávaného obrázku: hedvabi.bmp			
velikost obrázku: 548 x 752			
velikost akumulátoru: 548 x 752 x 11			
poloměr: 25 - 35, práh: 65 %, filtr: maska 3x3			
parametry kružnic: (a,b)... střed, r... poloměr, akumul... hodnota akumulátoru			
a [pixel]	b [pixel]	r [pixel]	akum [1]
415	442	27	44
153	295	27	43
250	485	27	43
372	542	27	43
97	526	26	42
213	529	27	42
325	582	28	42
391	317	26	41
315	517	26	41
354	217	27	41
336	408	26	40
76	474	26	40
278	404	27	40
423	558	27	40
337	341	26	39
204	399	26	39
146	392	27	39
136	456	27	38
405	496	27	38
221	589	30	38
63	331	26	37
390	385	27	37
326	276	26	36
49	391	26	36
305	461	26	36
233	342	27	36
460	411	27	36
96	414	27	36
292	221	26	35
206	290	27	35
229	204	26	34
258	268	26	34
198	458	26	34
280	316	26	32
166	235	26	31
275	604	26	30


Tabulka 6: Datový výstup z algoritmu využívající Houghovu transformaci.

B Řetězový kód a spektrální příznaky


Na obrázcích 72 - 77 jsou ukázány některé varianty řetězových kódů a spektra využitá pro získání spektrálních příznaků základních tvarů, kterými jsou čtverec a kružnice.




Obrázek 72: Kumulovaný řetězový kód čtverce.




Obrázek 73: Upravený kumulovaný řetězový kód čtverce.




Obrázek 74: Spektrum získané z upraveného kumulovaného kódu na obrázku 73. Je naznačeno logaritmické dělení pro tvorbu pásem, ve kterých jsou hodnoty sčítané do spektrálních příznaků.



Obrázek 75: Kumulovaný řetězový kód kružnice.




Obrázek 76: Upravený kumulovaný řetězový kód kružnice.



Obrázek 77: Spektrum získané z upraveného kumulovaného kódu na obrázku 76. Je naznačeno logaritmické dělení pro tvorbu pásem, ve kterých jsou hodnoty sčítané do spektrálních příznaků.

C Rozpoznávání vláken směsné příze


V této části je ukázáno praktické použití rozpoznávacího algoritmu, který má za úkol určit typ každého vlákna v řezu příze s více typy vláken v mikroskopickém snímku (kapitola 8).




Obrázek 78: Příčný řez s více typy vláken.



Obrázek 79: Vlákná prvního typu (třídy) z řezu na obrázku 78. Obrázek je invertován.




Obrázek 80: Vlákna druhého typu (třídy) z řezu na obrázku 78. Obrázek je invertován.




Obrázek 81: Grafické znázornění typů vláken do vstupního obrázku 78. Zeleně jsou označena vlákna první třídy, červeně vlákna třídy druhé.

D Měření fyzikálních vlastností nanovláken

Tato část ukazuje praktické použití algoritmu realizující měření fyzikálních vlastností vláken na snímcích z elektronového mikroskopu. Na obrázku 82 je snímek nanovláčkové struktury, který je využit jako vstup. V další části je algoritmus aplikován na více výřezů s rozdílnou velikostí (Obrázek 83 a Tabulka 7). Tento postup lze použít pro určení úspěšnosti algoritmu (především správného nastavení parametrů v části předzpracování) a stanovení nejvhodnější velikosti výřezu pro určení globálních hodnot měřených parametrů. Dále je algoritmus aplikován na stejný obrázek rozdělený do rastru stejně velkých výřezů (500×500), na kterých se postupně provádí měření (Obrázek 84, Tabulky 8 - 11). To může být použito při určování homogenity materiálu. V poslední části je na sérii obrázků vizualizován krok po kroku daný algoritmus (Obrázky 85 - 100).




Obrázek 82: Snímek nanovláčkové struktury nasnímaný elektronovým mikroskopem.



Obrázek 83: Snímek nanovláknenné struktury s vizualizací oblastí výřezů.

velikost obrazových dat ([pixel] x [pixel])	500 x 500	750 x 750	1000 x 1000	1250 x 1250	1500 x 1500	1750 x 1750	2000 x 2000
parametr zaplnění [%]	39,624	39,298	40,165	39,751	41,455	41,783	40,814
aritmetický průměr poloměru vláken [nm]	128,974	126,654	121,081	116,236	120,510	119,550	117,735
směrodatná odchylka poloměru vláken [nm]	59,545	62,870	63,673	59,023	70,062	71,299	67,002
rozptyl poloměru vláken [nm ²]	3545,820	3952,660	4054,220	3483,750	4908,640	5083,570	4489,240
aritmetický průměr velikosti děr [nm]	182,776	210,989	213,193	218,590	214,725	212,005	216,669
směrodatná odchylka velikosti děr [nm]	92,299	112,944	119,940	118,929	119,325	116,688	124,678
rozptyl velikosti děr [nm ²]	8519,13	12756,40	14385,60	14144,20	14238,40	13616,10	15544,50
čas vykonávání algoritmu [s]	11,787	27,759	58,084	124,619	213,256	356,616	596,047

Tabulka 7: Hodnoty měření v závislosti na velikosti obrazových dat.



Obrázek 84: Snímek nanovláknenné struktury s vizualizací oblastí výřezů.

index výřezu	1	2	3	4
parametr zaplnění [%]	39,624	42,463	35,170	44,881
aritmetický průměr poloměru vláken [nm]	128,974	132,622	106,473	124,627
směrodatná odchylka poloměru vláken [nm]	59,547	86,594	48,544	87,315
rozptyl poloměru vláken [nm ²]	3545,820	7498,530	2356,540	7623,970
aritmetický průměr velikosti děr [nm]	182,776	242,307	209,430	156,961
směrodatná odchylka velikosti děr [nm]	92,299	139,970	130,189	85,118
rozptyl velikosti děr [nm ²]	9519,130	19591,700	16949,300	7245,060
čas vykonávání algoritmu [s]	12,332	12,607	13,410	11,802

Tabulka 8: Hodnoty měření oblastí 1 – 4.

index výřezu	5	6	7	8
parametr zaplnění [%]	42,780	41,250	41,075	34,846
aritmetický průměr poloměru vláken [nm]	107,778	115,738	119,656	106,110
směrodatná odchylka poloměru vláken [nm]	51,597	63,552	84,384	46,656
rozptyl poloměru vláken [nm ²]	2662,270	4038,910	7120,670	2176,740
aritmetický průměr velikosti děr [nm]	165,852	219,215	194,792	204,587
směrodatná odchylka velikosti děr [nm]	118,766	101,924	93,657	99,867
rozptyl velikosti děr [nm ²]	14105,500	10388,600	8771,610	9943,400
čas vykonávání algoritmu [s]	12,395	12,831	13,855	14,039


Tabulka 9: Hodnoty měření oblastí 5 – 8.

index výřezu	9	10	11	12
parametr zaplnění [%]	37,942	41,066	42,990	40,803
aritmetický průměr poloměru vláken [nm]	99,961	123,208	123,665	120,655
směrodatná odchylka poloměru vláken [nm]	39,351	57,641	73,140	83,108
rozptyl poloměru vláken [nm ²]	1548,510	3322,510	5349,400	6906,860
aritmetický průměr velikosti děr [nm]	212,054	155,218	263,483	189,410
směrodatná odchylka velikosti děr [nm]	126,979	85,534	143,843	119,825
rozptyl velikosti děr [nm ²]	16123,600	7316,000	20690,800	14358,100
čas vykonávání algoritmu [s]	12,895	12,076	12,611	12,413


Tabulka 10: Hodnoty měření oblastí 9 – 12.

index výřezu	13	14	15	16
parametr zaplnění [%]	41,283	47,616	38,830	41,989
aritmetický průměr poloměru vláken [nm]	97,862	113,834	122,318	116,638
směrodatná odchylka poloměru vláken [nm]	41,134	68,694	65,789	61,360
rozptyl poloměru vláken [nm ²]	1691,980	4718,880	4328,200	3765,080
aritmetický průměr velikosti děr [nm]	173,045	192,835	234,414	202,749
směrodatná odchylka velikosti děr [nm]	106,202	72,477	178,394	113,091
rozptyl velikosti děr [nm ²]	11278,800	5252,900	31824,300	12789,700
čas vykonávání algoritmu [s]	12,198	13,321	13,166	12,895

Tabulka 11: Hodnoty měření oblastí 13 – 16.




Obrázek 85: Obrázek vstupující do zpracování.




Obrázek 86: Hranový obrázek. Hrany představují hranice vláken.



Obrázek 87: Binární obrázek získaný prahováním vstupního obrázku.




Obrázek 88: Grafické znázornění zakřivení hranic vláken v barevné teplotní stupnici. Hodnoty jsou pro vizuální názornost vyváženy vhodným koeficientem.




Obrázek 89: Vizualizace hran ve vstupním obraze. Zelené hrany jsou získány pomocí hranového detektoru, modře jsou znázorněny prodlužující hranové segmenty a červené jsou spojnice dvou hran.



Obrázek 90: Součet obrázku úplných hran a naprahaného obrázku.




Obrázek 91: Upravený skelet naprahovaného obrázku.




Obrázek 92: Aplikace podmíněné dilatace k získání objektů odpovídající vláknům.




Obrázek 93: Označkový obrázek vláken.




Obrázek 94: Upravený skelet podmíněné dilatace.




Obrázek 95: Vizualizace konečných hran na vstupním obrázku.




Obrázek 96: Vizualizace vzdálenostní funkce vláken.




Obrázek 97: Označkový obrázek děr.



Obrázek 98: Vizualizace vzdálenostní funkce děr.



Obrázek 99: Vizualizace výstupu transformace rozvodí.




Obrázek 100: Upravený skelet děr.

E Chlupatost příze


Snímky ze zásobníku příze (kapitola 10) lze použít k hodnocení chlupatosti. Ta se vyjadřuje pomocí *funkce chlupatosti* $Z(r)$ [42]. Pojmem *chlup* se dá zjednodušeně chápat *odstávající vlákno*, které nepatří do těla příze. Někdy se tato funkce nazývá jako *funkce zčernání*, protože se běžně počítá u mikroskopických snímků se zadním osvětlením, které se předzpracují transformací jasové stupnice na binární. Funkce chlupatosti potom vyjadřuje relativní četnost objektových bodů (černých) v závislosti na vzdálenosti od osy těla příze.

Snímky ze zásobníku jsou získány s předním osvětlením, což je první odlišnost. Dalším rozdílem je uspořádání příze do plošné struktury, kdy se funkce chlupatosti neurčuje individuálně pro jednu přízi, ale chlupy sousedních přízí mohou ovlivnit funkci chlupatosti i u přízi již nejsou součástí. Dále je nezávislá proměnná funkce chlupatosti, tedy vzdálenost od osy, určována jako vzdálenost od hranice těla příze. Tento postup tedy vyhodnocuje pouze odstávající vlákna a nepostihuje vady, které způsobí lokálně výraznou změnu poloměru.


Průběhy uvedené na obrázcích 104, 105 tedy vyjadřují průměrnou relativní četnost odstávajících vláken v závislosti na vzdálenosti od hranice těla příze. Na obrázku 101 je snímek příze na zásobníku, který je použit pro dané hodnocení. Obrázky 102 a 103 jsou předzpracované binární obrázky, které obsahují těla přízí a těla přízí s chlupy. Získané průběhy by bylo možné převést do reálných jednotek. Podstatný je ale tvar získaného průběhu.




Obrázek 101: Výřez snímku ze zásobníku použitý k hodnocení chlupatosti.




Obrázek 102: Binární obrázek obsahující pouze těla paralelně uložených přízí.



Obrázek 103: Binární obrázek obsahující odstávající vlákna (chlupy).



Obrázek 104: Průběh chlupatosti přize na snímku 101 pro výřez se 400 řádky.



Obrázek 105: Průběh chlupatosti přize na snímku 101. Data obsahují 4000 obrazových řádků.